

# ESTATÍSTICA II Ec/Fi

Econometria – Parte 1 (cap 2, 3 e 4 do Wooldridge)

## O que é?

- Na origem: Análise quantitativa dos fenómenos económicos pelo desenvolvimento simultâneo da teoria e da observação recorrendo a procedimentos de inferência adequados.
- Hoje em dia mais virada para a aplicação de **técnicas estatísticas** à análise de dados económicos, financeiros, sociais, etc. com o objetivo de estimar **relações** entre uma determinada **variável dependente** e um conjunto de **variáveis explicativas**
- Exemplos:
  - Consumo= f(rendimento disponível)
  - Salário=f(escolaridade, experiência, idade, género)

## Finalidade da Econometria:

- Testar a validade de teorias

- Será que o salário depende do nível de escolaridade, da experiência profissional, da idade ou do gênero?

Salário =  $f(\text{escolaridade, experiência, idade, gênero})$

- Efetuar previsões

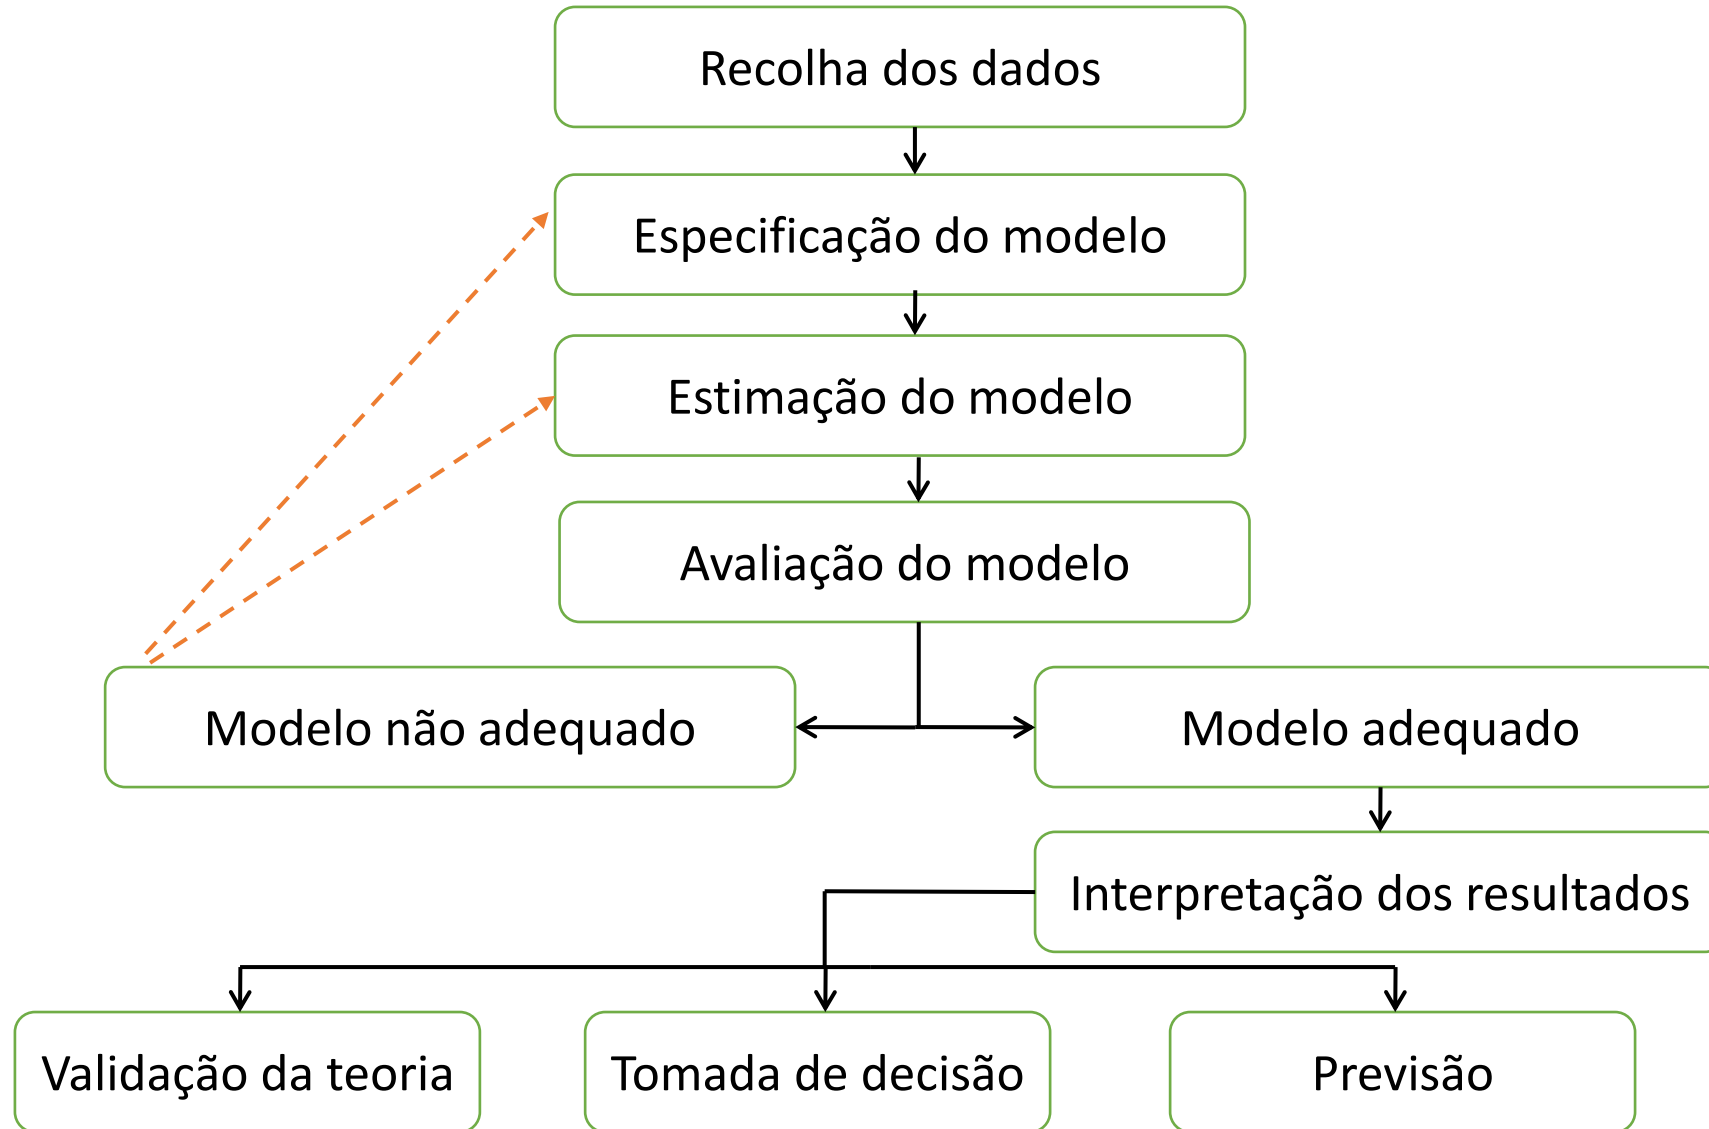
- Qual o salário esperado para um individuo com certas características?

- Fundamentar quantitativamente políticas

- Aumentar o nível de escolaridade de certa população tem consequências na sua produtividade?

Produtividade =  $f(\text{escolaridade, experiência, idade, gênero})$

# Metodologia



# Tipos de Dados

Dados seccionais (*cross-section*):

- N entidades (indivíduos, empresas, famílias, ....)
- 1 observação por entidade

Dados temporais (*time serie*):

- 1 entidade (empresa, país, ...)
- T observações por entidade

Dados de painel (*panel data*):

- N entidades
- T observações por cada entidade

Outros tipos de dados como o “pooled data”

# Dados Seccionais

- Exemplo: Salário =  $f(\text{escolaridade, experiência, idade, género})$  a ser estimado com base numa amostra de  $N$  indivíduos (1 observação por indivíduo);
- O tempo está “fixo” – Todas as observações se referem ao “mesmo” período temporal;
- Neste quadro é possível por vezes considerar-se que a amostra corresponde a **observações independentes** com **idêntica variância** já que, como se irá ver, a média vai ser dada pelo modelo.
- Mas ... nem sempre a situação é tão “simples”: Podem aparecer vários problemas quer ao nível do modelo (por exemplo a variância não ser a idêntica para todas as observações) quer dos dados (alguns casos não são observáveis ou são observáveis com erro)

# Dados Temporais

- Exemplo: Modelo que relacione a Taxa de Juro a 3 meses dos títulos do tesouro de determinado país (TxJuro) com a inflação (inf) e o deficit orçamental (def), isso é  $TxJuro = f(inf, def)$ . Dispõe-se de uma amostra cobrindo T anos;
- A entidade está fixa e observa-se o comportamento ao longo do tempo;
- As observações estão **ordenadas** ao contrário do que sucede com dados seccionais; A periodicidade costuma ser constante (anos, trimestres, meses, semanas,...) embora possam existir “falhas” na série de valores.
- Em termos estatísticos, o primeiro problema que surge é que quase nunca se pode considerar que períodos de tempo consecutivos constituem observações independentes e portanto ter-se-á de recorrer a modelos mais complexos;
- A ser estudado na unidade curricular de Econometria

# Causalidade e significância estatística

- O modelo procura identificar os **determinantes** do comportamento de uma variável de interesse: O que explica o salário de um trabalhador? Quais as características que determinam o preço de um imóvel?
- Na avaliação do modelo
  - verifica-se se as variáveis explicativas consideradas são **estatisticamente significativas** para explicar o comportamento da variável de interesse, na procura de uma **possível relação de causalidade**
  - **Causalidade e significância estatística** - . A causalidade vai para além da significância estatística já que envolve considerações teóricas



# Análise *ceteris paribus*

- Num modelo envolvendo várias variáveis explicativas o foco situa-se, por vezes, nos efeitos de uma delas sobre a variável dependente.
  - No modelo  $\text{Salário} = f(\text{escolaridade, experiência, idade, género})$  o nosso interesse pode estar no estudo da discriminação de género, isto é, no efeito específico da variável género no salário
- Obtém-se o **efeito parcial / marginal** de cada variável explicativa sobre a variável de interesse, sob a condição de ***ceteris paribus***, isto é, assumindo que tudo o resto se mantém constante.
  - Pode interessar apenas o sinal do efeito (se positivo / negativo existe uma relação direta / inversa com a variável dependente) ou também a sua intensidade

# Enquadramento do modelo

- Modelo com **dados seccionais** (mesmo período temporal)

$$y = f(x_1, x_2, \dots, x_k)$$

- Os dados têm natureza não experimental (estão fora do controle de quem vai especificar o modelo) logo quer a variável  $y$  quer as variáveis explicativas  $x_1, x_2, \dots, x_k$  vão ser consideradas aleatórias.
- Para aliviar a notação vai abandonar-se a convenção em torno das maiúsculas/minúsculas. As letras maiúsculas corresponderão agora a vetores ou matrizes.

# O objetivo

- Modelo  $\rightarrow y = f(x_1, x_2, \dots, x_k)$

Salário=f(educação,experiência,idade,sexo)

- Das várias características da variável  $y$ , vai modelar-se o **valor esperado** de  $y$  **condicionado** por  $x_1, x_2, \dots, x_k$ . Relação estatística versus relação matemática
- Um modelo é sempre uma representação simplificada da realidade que permite sublinhar os determinantes mais importantes do comportamento da variável  $y$ .
- Assim, existem sempre variáveis explicativas (que se pensam menos relevantes) que não são incluídas no modelo.

# Modelo de Regressão Linear Múltipla (MRLM)

- Objetivo genérico: explicar  $E(y|\mathbf{x})$
- **Regressão linear:**  $E(y|\mathbf{x})$  é função linear de um conjunto de parâmetros  $\beta$ , isto é

$$E(y|\mathbf{x}) = \beta_0 + \beta_1 x_1 + \cdots + \beta_k x_k$$

- O modelo é linear nos parâmetros e não nas variáveis, isto é, pode acontecer que  $x_2 = x_1^2$  ou  $x_3 = \ln(x_2)$ .
- Fazendo  $u = y - E(y|\mathbf{x})$ , pode escrever-se

$$y = \beta_0 + \beta_1 x_1 + \cdots + \beta_k x_k + u$$

# Especificação do MRLM

- O modelo vai ser estimado com base numa amostra com  $N$  observações. Recorda-se que cada observação é dada por

$$(y_i, x_{i1}, x_{i2}, \dots, x_{ik}) \text{ para } i = 1, 2, \dots, N$$

- Tem-se então

$$y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik} + u_i \quad (i = 1, \dots, N)$$

Apenas as variáveis  $y$  e  $x_1, x_2, \dots, x_k$  são observáveis ( $N$  obs.)

$u$ : termo de erro

$\beta$ : parâmetros – serão estimados

$k$ : nº variáveis explicativas

$k + 1$ : nº parâmetros (em modelos incluindo termo independente)

$N$ : nº observações

# Especificação do MRLM

Em termos matriciais vem

$$E(Y|\mathbf{X}) = \mathbf{X}\beta \quad \text{ou} \quad Y = \mathbf{X}\beta + U$$

Com

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix} \quad X = \begin{bmatrix} 1 & x_{11} & \cdots & x_{1k} \\ 1 & x_{21} & \cdots & x_{2k} \\ \vdots & \vdots & & \vdots \\ 1 & x_{N1} & \cdots & x_{Nk} \end{bmatrix}, \quad U = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_N \end{bmatrix} \quad \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix}$$

$Y$  e  $U$  são vetores com  $N$  linhas ( $n^\circ$  observações)

$X$  matriz ( $N \times (k + 1)$ ) - cada linha uma observação, 1ª coluna é o termo independente e depois cada coluna cada uma variável

$\beta$  vetor com  $k + 1$  linhas (coeficientes da regressão)

Exemplo: Como interpretar  $u$ ?

$$\text{salário} = \beta_0 + \beta_1 \text{educ} + \beta_2 \text{exper} + \beta_3 \text{idade} + \beta_4 \text{sexo} + u$$

$U = Y - E(Y|\mathbf{X})$  diferença entre  $Y$  e o seu valor esperado condicionado.

$u$  também pode ser interpretado como o efeito no salário das variáveis explicativas que não estão explicitadas no modelo, fixadas essas, claro.

# Estimação dos coeficientes

Modelo:  $E(y|X) = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k$

Amostra:  $y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik} + u_i \quad (i = 1, \dots, N)$


ou, na forma matricial,  $Y = X\beta + U$

- Existindo  $k + 1$  parâmetros desconhecidos a nossa 1ª preocupação será estimá-los
- Designe-se então por  $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$  as estimativas obtidas a partir das quais se obtém:
  - Valores ajustados:  $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \dots + \hat{\beta}_k x_{ik}$
  - Resíduos:  $\hat{u}_i = y_i - \hat{y}_i$
- Vamos escolher os valores  $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$  que minimizam  $\sum_{i=1}^N \hat{u}_i^2$



# Valores ajustados e resíduos

Ilustração com um regressor (Wooldridge)



# Variável residual versus resíduos




Figura tirada do capítulo 10 do livro de Estatística (Murteira *et al*)

Cuidado com a notação que é diferente da utilizada no Wooldridge

## Estimação do Modelo:

- **Método dos Mínimos Quadrados (OLS):**  $\min \sum_{i=1}^N \hat{u}_i^2$
- Como  $\sum_{i=1}^N \hat{u}_i^2 = \sum_{i=1}^N (y_i - \hat{y}_i)^2$   
 $= \sum_{i=1}^N (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \dots - \hat{\beta}_k x_{ik})^2$

as condições de primeira ordem vêm (derivadas parciais em ordem a cada  $\hat{\beta}$ ):

$$\begin{cases} \sum_{i=1}^N (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \dots - \hat{\beta}_k x_{ik}) = 0 \\ \sum_{i=1}^N x_{ij} (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \dots - \hat{\beta}_k x_{ik}) = 0 \quad j = 1, \dots, k \end{cases}$$

# OLS – Método dos Mínimos quadrados

- Em termos matriciais vem
  - Valores ajustados:  $\hat{Y} = \mathbf{X}\hat{\beta}$
  - Resíduos:  $\hat{U} = Y - \hat{Y}$
- Método dos mínimos quadrados

$$\min \hat{U}^T \hat{U}$$

- *Condições de primeira ordem*

$$\mathbf{X}^T (Y - \mathbf{X}\hat{\beta}) = 0$$

ou seja  $\mathbf{X}^T Y = \mathbf{X}^T \mathbf{X}\hat{\beta}$

- Estimador MQ

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T Y$$

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$$

$$\mathbf{X}^T \mathbf{X} = \begin{bmatrix} N & \sum_{i=1}^N x_{i1} & \cdots & \sum_{i=1}^N x_{ik} \\ \sum_{i=1}^N x_{i1} & \sum_{i=1}^N x_{i1}^2 & \cdots & \sum_{i=1}^N x_{i1} x_{ik} \\ \vdots & \vdots & \ddots & \vdots \\ \sum_{i=1}^N x_{ik} & \sum_{i=1}^N x_{ik} x_{i1} & \cdots & \sum_{i=1}^N x_{ik}^2 \end{bmatrix} \quad \mathbf{X}^T \mathbf{Y} = \begin{bmatrix} \sum_{i=1}^N y_i \\ \sum_{i=1}^N x_{i1} y_i \\ \vdots \\ \sum_{i=1}^N x_{ik} y_i \end{bmatrix}$$

Já que

$$X^T X = \begin{bmatrix} 1 & 1 & 1 & \cdots & 1 \\ x_{11} & x_{21} & x_{31} & \cdots & x_{n1} \\ x_{12} & x_{22} & x_{32} & \cdots & x_{n2} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ x_{1k} & x_{2k} & x_{3k} & \cdots & x_{nk} \end{bmatrix} \begin{bmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1k} \\ 1 & x_{21} & x_{22} & \cdots & x_{2k} \\ 1 & x_{31} & x_{32} & \cdots & x_{3k} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{nk} \end{bmatrix}$$
$$= \begin{bmatrix} N & \sum_{i=1}^N x_{i1} & \sum_{i=1}^N x_{i2} & \cdots & \sum_{i=1}^N x_{ik} \\ \sum_{i=1}^N x_{i1} & \sum_{i=1}^N x_{i1}^2 & \sum_{i=1}^N x_{i1}x_{i2} & \cdots & \sum_{i=1}^N x_{i1}x_{ik} \\ \sum_{i=1}^N x_{i2} & \sum_{i=1}^N x_{i2}x_{i1} & \sum_{i=1}^N x_{i2}^2 & \cdots & \sum_{i=1}^N x_{i2}x_{ik} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ \sum_{i=1}^N x_{ik} & \sum_{i=1}^N x_{ik}x_{i1} & \sum_{i=1}^N x_{ik}x_{i3} & \cdots & \sum_{i=1}^N x_{ik}^2 \end{bmatrix}$$

e que

$$X^T Y = \begin{bmatrix} 1 & 1 & 1 & \cdots & 1 \\ x_{11} & x_{21} & x_{31} & \cdots & x_{n1} \\ x_{12} & x_{22} & x_{32} & \cdots & x_{n2} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ x_{1k} & x_{2k} & x_{3k} & \cdots & x_{nk} \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ \cdots \\ y_n \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^N y_i \\ \sum_{i=1}^N x_{i1} y_i \\ \sum_{i=1}^N x_{i2} y_i \\ \cdots \\ \sum_{i=1}^N x_{ik} y_i \end{bmatrix}$$

# Caso particular 1 – Regressão linear simples

Modelo com **um** regressor: modelo linear simples

$$y_i = \beta_0 + \beta_1 x_i + u_i$$

$$\hat{\beta} = \left[ \frac{\sum_{i=1}^N (x_i - \bar{x}) y_i}{\sum_{i=1}^N (x_i - \bar{x})^2} = \frac{\bar{y} - \hat{\beta}_1 \bar{x}}{\sum_{i=1}^N (x_i - \bar{x})^2} = \frac{s_{yx}}{s_x^2} \right]$$

A obtenção destes resultados é feita recorrendo, uma vez mais, às condições de 1ª ordem escritas agora para esta situação particular:

$$\begin{cases} \sum_{i=1}^N (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0 \\ \sum_{i=1}^N x_i (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0 \end{cases} \Leftrightarrow \begin{cases} \sum_{i=1}^N y_i - N \hat{\beta}_0 - \hat{\beta}_1 \sum_{i=1}^N x_i = 0 \\ \sum_{i=1}^N x_i y_i - \hat{\beta}_0 \sum_{i=1}^N x_i - \hat{\beta}_1 \sum_{i=1}^N x_i^2 = 0 \end{cases}$$



# Caso particular 1 – Regressão linear simples

Da 1ª equação vem  $\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$

Utilizando este resultado na 2ª equação vem

$$\sum_{i=1}^N x_i y_i - (\bar{y} - \hat{\beta}_1 \bar{x}) \sum_{i=1}^N x_i - \hat{\beta}_1 \sum_{i=1}^N x_i^2 = 0$$

$$\sum_{i=1}^N x_i y_i - \bar{y} \sum_{i=1}^N x_i + \hat{\beta}_1 \bar{x} \sum_{i=1}^N x_i - \hat{\beta}_1 \sum_{i=1}^N x_i^2 = 0$$

$$\sum_{i=1}^N x_i y_i - N \bar{x} \bar{y} + N \hat{\beta}_1 \bar{x}^2 - \hat{\beta}_1 \sum_{i=1}^N x_i^2 = 0$$

$$\sum_{i=1}^N x_i y_i - N \bar{x} \bar{y} - \hat{\beta}_1 (\sum_{i=1}^N x_i^2 - N \bar{x}^2) = 0$$

$$\hat{\beta}_1 = \frac{\sum_{i=1}^N x_i y_i - N \bar{x} \bar{y}}{(\sum_{i=1}^N x_i^2 - N \bar{x}^2)} = \frac{\sum_{i=1}^N (x_i - \bar{x}) y_i}{\sum_{i=1}^N (x_i - \bar{x})^2} = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^N (x_i - \bar{x})^2} = \frac{s_{yx}}{s_x^2}$$

## Caso particular 2 – Modelo só com *intercept*

Modelo **sem** regressores: só com termo independente (*intercept*)

$$y_i = \beta_0 + u_i$$
$$\hat{\beta}_0 = \bar{y}$$

Já que  $\sum_{i=1}^N \hat{u}_i^2 = \sum_{i=1}^N (y_i - \hat{\beta}_0)^2$

1ª derivada = 0:  $-2 \sum_{i=1}^N (y_i - \hat{\beta}_0) = 0 \Leftrightarrow -2 \sum_{i=1}^N y_i + 2N\hat{\beta}_0 = 0$   
 $\Leftrightarrow \hat{\beta}_0 = \bar{y}$

## Caso particular 3 – Regressão sem *intercept*

Modelo **sem termo independente** ( $\beta_0 = 0$ ): regressão na origem

$$y_i = \beta_1 x_{i1} + \cdots + \beta_k x_{ik} + u_i$$

Recorrer à expressão geral para obter  $\hat{\beta}_j$

Ter presente que este modelo **não verifica**  $\sum_{i=1}^N \hat{u}_i = 0$ , o que vai ter pesadas consequências nas propriedades dos estimadores.

Desde já se pode adiantar que não incluir termo independente quando se deveria é **muito mais grave** do que incluir quando não se deveria. Assim, só se utiliza este modelo em situações muito particulares.

**Exemplo:** Considere o modelo

$$preço = \beta_0 + \beta_1 area + \beta_2 quartos + u$$

onde o **preço de uma casa**, em milhares de dólares, depende da **área** (m<sup>2</sup>) e do **número de quartos** (dados adaptados do ficheiro HPRICE1 do Wooldridge – Os pés quadrados foram convertidos em m<sup>2</sup> – e disponíveis no FENIX).

Wooldridge Source: Collected from the real estate pages of the Boston Globe during 1990. These are homes that were sold in the Boston, MA area.

# Estimação OLS - Exemplo

Modelo estimado

$$\widehat{\text{preço}} = -19.286 + 1.384\text{area} + 15.121\text{quartos}$$

Output EXCEL

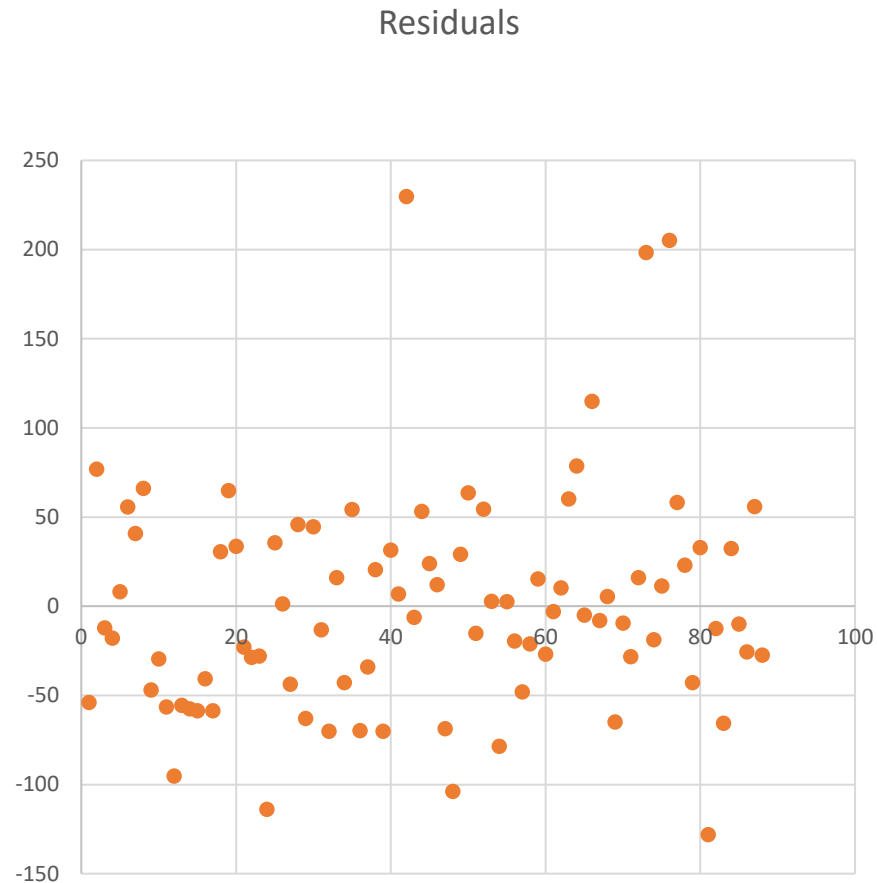
SUMMARY OUTPUT						
Regression Statistics						
Multiple R	0.794906945					
R Square	0.63187705					
Adjusted R Square	0.623215334					
Standard Error	63.04837628					
Observations	88					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	2	579971.1994	289985.5997	72.95055817	3.58672E-19	
Residual	85	337883.3088	3975.097751			
Total	87	917854.5083				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	-19.28550028	31.0475285	-0.621160563	0.536156232	-81.0163048	42.44530424
area(m2)	1.38360615	0.148943494	9.289470184	1.40049E-14	1.08746658	1.67974572
quartos	15.12133684	9.488597692	1.593632413	0.114730383	-3.744537442	33.98721112

# Estimação OLS - Exemplo

Em termos matriciais, viria para este exemplo

Dados (ver ficheiro)	Matrizes
Obs Preço área quartos	
1 300.0 226 4	$X = \begin{bmatrix} 1 & 226 & 4 \\ \dots & \dots & \dots \\ 1 & 165 & 4 \end{bmatrix}$ (88 linhas por 3 colunas)
2 370.0 193 3	
3 191.0 128 3	
....	
86 202.5 146 3	$Y = \begin{bmatrix} 300 \\ \dots \\ 242 \end{bmatrix}$ (88 linhas)
87 219.0 110 2	
88 242.0 165 4	
	$X^T X = \begin{bmatrix} 88 & 16465 & 314 \\ 16465 & 3330603 & 60838 \\ 314 & 60838 & 1182 \end{bmatrix}$ mat simétrica
	$(X^T X)^{-1} = \begin{bmatrix} 0.2424969362 & -0.0003691329 & -0.0454202476 \\ -0.0003691329 & 5.580785e - 06 & -0.0001891845 \\ -0.0454202476 & -0.0001891845 & 0.0226493766 \end{bmatrix}$
	$X^T Y = \begin{bmatrix} 25832.05 \\ 5210658.92 \\ 95993.60 \end{bmatrix}$ vetor de dimensão 3

# Estimação OLS – Exemplo



A ordem da observação na amostra ( $i$ ) está no eixo das abscissas enquanto os resíduos ( $\hat{u}_i$ ) estão no eixo das ordenadas.

$$\hat{u}_i = y_i - \hat{y}_i$$

Como para a 1ª obs, preço=300, area=226 e quartos=4 vem

$$\begin{aligned} \widehat{\text{preço}}_1 &= -19.286 + 1.384 \times 226 + 15.121 \times 4 \\ &= 353.894 \end{aligned}$$

$$\hat{u}_1 = 300 - 353.894 = -53.894$$

e, de forma semelhante,

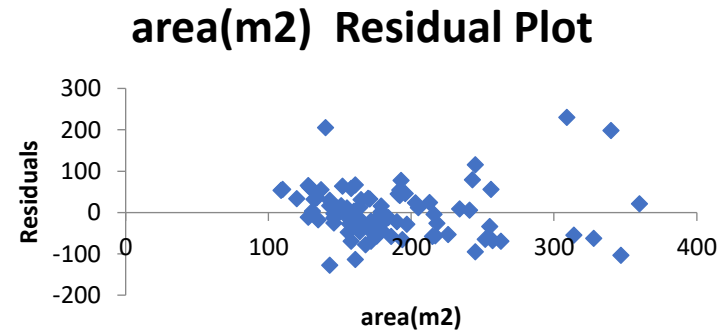
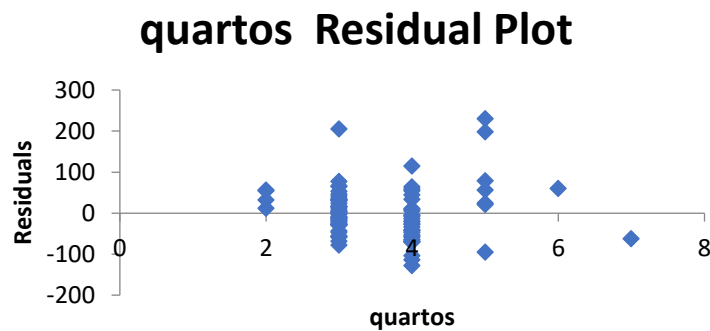
$$\hat{u}_2 = 370 - 293.114 = 76.884$$

....

$$\hat{u}_{88} = 242 - 269.495 = -27.495$$

# Estimação OLS – Exemplo

Como a ordem das observações é arbitrária num modelo seccional, torna-se muitas vezes mais interessante olhar para os resíduos em função de cada variável explicativa ou do valor da variável endógena.





# Propriedades dos resíduos OLS

Resíduos:  $\hat{u}_i = y_i - \hat{y}_i$

## Propriedades:

- $\sum_{i=1}^N \hat{u}_i = 0$  (modelos com termo independente)
- $\sum_{i=1}^N \hat{u}_i x_{ij} = 0, j=1, \dots, k$
- $\sum_{i=1}^N \hat{u}_i \hat{y}_i = 0$
- $\sum_{i=1}^N y_i^2 = \sum_{i=1}^N \hat{y}_i^2 + \sum_{i=1}^N \hat{u}_i^2$

Para demonstrar estas propriedades é necessário recordar as condições de 1ª ordem que se obtiveram anteriormente:

$$\begin{cases} \sum_{i=1}^N (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \dots - \hat{\beta}_k x_{ik}) = 0 \\ \sum_{i=1}^N x_{ij} (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \dots - \hat{\beta}_k x_{ik}) = 0 \quad j = 1, \dots, k \end{cases}$$

# Propriedades dos resíduos OLS

$$\begin{cases} \sum_{i=1}^N (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \dots - \hat{\beta}_k x_{ik}) = 0 \\ \sum_{i=1}^N x_{ij} (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \dots - \hat{\beta}_k x_{ik}) = 0 \quad j = 1, \dots, k \end{cases}$$

- **A propriedade 1** deriva diretamente da 1ª equação

$$\begin{aligned} \sum_{i=1}^N \hat{u}_i &= \sum_{i=1}^N (y_i - \hat{y}_i) \\ &= \sum_{i=1}^N (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \dots - \hat{\beta}_k x_{ik}) \\ &= 0 \quad (1^\text{ª} \text{ eq. derivada parcial de } \hat{U}^T \hat{U} \text{ em ordem a } \hat{\beta}_0) \end{aligned}$$

- **A propriedade 2** deriva da “segunda” equação

$$\begin{aligned} \sum_{i=1}^N \hat{u}_i x_{ij} &= \sum_{i=1}^N x_{ij} (y_i - \hat{y}_i) \\ &= \sum_{i=1}^N x_{ij} (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \dots - \hat{\beta}_k x_{ik}) \\ &= 0 \quad (2^\text{ª} \text{ eq. derivada parcial de } \hat{U}^T \hat{U} \text{ em ordem a } \hat{\beta}_j) \end{aligned}$$

# Propriedades dos resíduos OLS

**Propriedade 3** -  $\sum_{i=1}^N \hat{u}_i \hat{y}_i = 0$

$$\begin{aligned}\sum_{i=1}^N \hat{u}_i \hat{y}_i &= \sum_{i=1}^N \hat{u}_i (\hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_k x_{ik}) \\ &= \hat{\beta}_0 \sum_{i=1}^N \hat{u}_i + \hat{\beta}_1 \sum_{i=1}^N \hat{u}_i x_{i1} + \dots + \hat{\beta}_k \sum_{i=1}^N \hat{u}_i x_{ik} \\ &= 0\end{aligned}$$

aplicando

propriedade 1 ( $\sum_{i=1}^N \hat{u}_i = 0$ ) e

propriedade 2 ( $\sum_{i=1}^N \hat{u}_i x_{ij} = 0$  para  $j = 1, 2, \dots, k$ )

# Propriedades dos resíduos OLS

**Propriedade 4** -  $\sum_{i=1}^N y_i^2 = \sum_{i=1}^N \hat{y}_i^2 + \sum_{i=1}^N \hat{u}_i^2$

$$\begin{aligned}\sum_{i=1}^N y_i^2 &= \sum_{i=1}^N (\hat{y}_i + \hat{u}_i)^2 = \sum_{i=1}^N \hat{y}_i^2 + \sum_{i=1}^N \hat{u}_i^2 + 2 \sum_{i=1}^N \hat{y}_i \hat{u}_i \\ &= \sum_{i=1}^N \hat{y}_i^2 + \sum_{i=1}^N \hat{u}_i^2\end{aligned}$$

já que , pela propriedade 3,  $\sum_{i=1}^N \hat{y}_i \hat{u}_i = 0$

# Qualidade do Ajustamento

Modelo:  $y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + u$

Modelo estimado:  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \dots + \hat{\beta}_k x_k$

Para fazer uma primeira avaliação à qualidade do ajustamento, pode comparar-se  $\hat{y}_i$  com  $y_i$  e calcular o coeficiente de correlação

$$r_{y\hat{y}} = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\left( \left( \sum_{i=1}^n (y_i - \bar{y})^2 \right) \left( \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2 \right) \right)^{1/2}} = \frac{s_{y\hat{y}}}{s_y s_{\hat{y}}}$$

Como o sinal da correlação não é informativo (será sempre positiva uma vez que  $\hat{y}$  constitui a nossa melhor aproximação a  $y$ ) utiliza-se o seu quadrado,  $r_{y\hat{y}}^2$  (varia entre 0 e 1, quanto mais próximo de 1, melhor o ajustamento).

# Decomposição da variação total e $R^2$

A abordagem mais habitual consiste em avaliar qual a proporção da variação da variável  $y$  que é “explicada” pelo modelo, isto é, coberta pela variação de  $\hat{y}$ .

A ideia é decompor a variação total (SST) em termos da variação explicada (SSE) e da variação residual (SSR)

**Variação total (SST) = variação explicada (SSE) + variação residual (SSR)**

e ver o peso da variação explicada na variação total, definindo-se o coeficiente de determinação  $R^2$  como

$$R^2 = \frac{SSE}{SST} = 1 - \frac{SSR}{SST}$$

Antes de comentar esta medida, veja-se o significado das diferentes componentes envolvidas.

# Decomposição da variação total e $R^2$

**Variação total (SST) = variação explicada (SSE) + variação residual (SSR)**

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2$$

$$SSE = \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2 = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

$$y_i = \hat{y}_i + \hat{u}_i \text{ logo } \sum y_i = \sum \hat{y}_i + \sum \hat{u}_i = \sum \hat{y}_i \text{ (termo ind) e portanto } \bar{y} = \bar{\hat{y}}$$

$$SSR = \sum_{i=1}^n (\hat{u}_i - \bar{\hat{u}})^2 = \sum_{i=1}^n \hat{u}_i^2$$

como o modelo tem termo independente,  $\sum \hat{u}_i = 0$  e portanto  $\bar{\hat{u}} = 0$ .

$$\begin{aligned} SST &= \sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (y_i - \hat{y}_i + \hat{y}_i - \bar{y})^2 = \sum_{i=1}^n (\hat{u}_i + (\hat{y}_i - \bar{y}))^2 \\ &= \sum \hat{u}_i^2 + \sum (\hat{y}_i - \bar{y})^2 + 2 \sum \hat{u}_i (\hat{y}_i - \bar{y}) = SSR + SSE + 2 \sum \hat{u}_i \hat{y}_i - 2\bar{y} \sum \hat{u}_i \\ &= SSE + SSR \end{aligned}$$

Recordam-se as **propriedades dos resíduos** (modelos com termo independente)

$$\sum_{i=1}^n \hat{u}_i = 0$$

$$\sum_{i=1}^n \hat{u}_i x_{ij} = 0, j=1, \dots, k$$

$$\sum_{i=1}^n \hat{u}_i \hat{y}_i = 0$$

$$\sum_{i=1}^n y_i^2 = \sum_{i=1}^n \hat{y}_i^2 + \sum_{i=1}^n \hat{u}_i^2$$

# Quadro ANOVA

- Quadro de análise de variância: decomposição da variação total de Y

	SS	DF	MS
Explicados	$\sum (\hat{y}_i - \bar{y})^2$	$k$	MSE
Residual	$\sum \hat{u}_i^2$	$n - k - 1$	$MSR = \hat{\sigma}^2$
Total	$\sum (y_i - \bar{y})^2$	$n - 1$	$s_y^2$

- Coeficiente de determinação:

$$R^2 = \frac{SSE}{SST}, \quad 0 \leq R^2 \leq 1$$

Mede a proporção da variação amostral de  $y$  explicada pela regressão



# $R^2$ - Interpretação

Alguns comentários:

- Recorrendo às propriedades dos resíduos, mostra-se que no MRLM (com termo independente)  $r_{y\hat{y}}^2 = R^2$ .

$$\bar{\hat{y}} = \frac{\sum \hat{y}_i}{n} = \frac{\sum (y_i - \hat{u}_i)}{n} = \frac{\sum y_i}{n} - \frac{\sum \hat{u}_i}{n} = \bar{y} \quad \text{Propriedade 1 dos resíduos OLS}$$

$$\begin{aligned}\sum (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}}) &= \sum (\hat{y}_i - \bar{y} + \hat{u}_i)(\hat{y}_i - \bar{y}) \\ &= \sum ((\hat{y}_i - \bar{y})^2 + \hat{u}_i(\hat{y}_i - \bar{y})) \\ &= \sum (\hat{y}_i - \bar{y})^2 + \sum \hat{u}_i \hat{y}_i - \bar{y} \sum \hat{u}_i \\ &= \sum (\hat{y}_i - \bar{y})^2 \quad \text{Propriedades 1 e 3 dos resíduos OLS}\end{aligned}$$

$$\begin{aligned}r_{y\hat{y}}^2 &= \frac{(\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}}))^2}{(\sum_{i=1}^n (y_i - \bar{y})^2) (\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2)} = \frac{(\sum (\hat{y}_i - \bar{y})^2)^2}{(\sum_{i=1}^n (y_i - \bar{y})^2) (\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2)} \\ &= \frac{SSE}{SST} = R^2\end{aligned}$$

# $R^2$ - Interpretação

Alguns comentários:

- De um modo geral  $SSE = R^2 SST$  ou  $SSR = (1 - R^2) SST$   
$$SSE = R^2 SST \Leftrightarrow SST - SSR = R^2 SST \Leftrightarrow SST - R^2 SST = SSR$$
- $R^2 = 1$  significa que  $SSR = \sum_{i=1}^n \hat{u}_i^2 = 0$ , isto é, que o ajustamento é perfeito  $\hat{y}_i = y_i$ .
- $R^2 = 0$  significa que  $SSE = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = 0$ , isto é, que  $\hat{y}_i = \bar{y}$  ( $\hat{y}_i$  é constante) e que o modelo nada adianta.
- A interpretação do valor do  $R^2$  levanta ainda 2 problemas:
  - Consoante o problema que se esteja a modelar, o  $R^2$  assume valores bem diferentes: um valor de 0.3 tanto pode corresponder a um bom valor como a um mau modelo (depende do que se esteja a modelar)
  - Quando se acrescentam variáveis explicativas ao modelo, mostra-se que o  $R^2$  não pode decrescer! Assim, o  $R^2$  tende a valorizar modelos com excesso de variáveis explicativas.

# $R^2$ ajustado

- A solução mais comum para corrigir este último problema consiste em recorrer ao coeficiente de determinação corrigido (Adjusted R square ou  $\bar{R}^2$ ) que “penaliza” o modelo pela introdução de novas variáveis explicativas.

$$\bar{R}^2 = 1 - \frac{SSR/(n - k - 1)}{SST/(n - 1)}$$

O inconveniente desta nova medida é não ter uma interpretação tão intuitiva quanto o  $R^2$ .

Também se mostra que

$$\bar{R}^2 = 1 - (1 - R^2) \frac{(n - 1)}{(n - k - 1)}$$

# $R^2$ - Comparação de modelos

- Formas alternativas do coeficiente de determinação e **comparação de modelos:**

	$R^2 = \frac{SSE}{SST}$	$r_{y\hat{y}}^2 = cor(Y, \hat{Y})^2$	$\bar{R}^2 = 1 - (1 - R^2) \frac{n - 1}{n - k - 1}$
Os modelos têm todos termo independente	V		V
Os modelos têm todos a mesma variável dependente (y)	V		V
O número de variáveis explicativas (k) é o mesmo	V	V	

Um  $R^2$  elevado (baixo) não significa que o modelo descreva (não descreva) convenientemente os dados: será necessário testar a validade do modelo

# Output Excel

Modelo estimado:

$$\widehat{preço} = -19.286 + 1.3836 \text{ area} + 15.121 \text{ quartos}$$

Identificar:  $r_{y\hat{y}} = 0.7949$   $R^2 = 0.6319$   $\bar{R}^2 = 0.6232$   $n = 88$

$$SST = 917854.5 \quad SSE = 579971.2 \quad SSR = \sum \hat{u}_i^2 = 337883.3$$

$$\hat{\beta} = \begin{bmatrix} -19.286 \\ 1.3836 \\ 15.121 \end{bmatrix}$$

SUMMARY OUTPUT						
Regression Statistics						
Multiple R	0.794906945					
R Square	0.63187705					
Adjusted R Square	0.623215334					
Standard Error	63.04837628					
Observations	88					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	2	579971.1994	289985.5997	72.95055817	3.58672E-19	
Residual	85	337883.3088	3975.097751			
Total	87	917854.5083				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	-19.28550028	31.0475285	-0.621160563	0.536156232	-81.0163048	42.44530424
area(m2)	1.38360615	0.148943494	9.289470184	1.40049E-14	1.08746658	1.67974572
quartos	15.12133684	9.488597692	1.593632413	0.114730383	-3.744537442	33.98721112

# Output Views

Modelo estimado:

$$\widehat{pre\c{c}o} = -19.286 + 1.3836 \textit{ area} + 15.121 \textit{ quartos}$$

Identificar:  $R^2 = 0.6319$   $\bar{R}^2 = 0.6232$   $n = 88$   $SSR = \sum \hat{u}_i^2 = 337883.3$

$$\widehat{\beta} = \begin{bmatrix} -19.286 \\ 1.3836 \\ 15.121 \end{bmatrix}$$

Dependent Variable: PRECO				
Method: Least Squares				
Date: 03/24/20 Time: 17:00				
Sample: 1 88				
Included observations: 88				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-19.28550	31.04753	-0.621161	0.5362
AREA	1.383606	0.148943	9.289470	0.0000
QUARTOS	15.12134	9.488598	1.593632	0.1147
R-squared	0.631877	Mean dependent var		293.5460
Adjusted R-squared	0.623215	S.D. dependent var		102.7134
S.E. of regression	63.04838	Akaike info criterion		11.15918
Sum squared resid	337883.3	Schwarz criterion		11.24363
Log likelihood	-488.0038	Hannan-Quinn criter.		11.19320
F-statistic	72.95056	Durbin-Watson stat		1.857617
Prob(F-statistic)	0.000000			

Modelo estimado:

$$\widehat{\text{preço}} = -19.286 + 1.3836 \text{ area} + 15.121 \text{ quartos}$$

2 - Stata/SE 13.1 - C:\Esmeralda\Docencia\2014-15-MPII\2014-15-MPII\precasa.dta - [Results]

File Edit Data Graphics Statistics User Window Help

979-696-4601 (fax)

Single-user Stata perpetual license:  
Serial number: 401306237695  
Licensed to: Esmeralda Ramalho  
Universidade de Evora

Notes:  
1. (/v# option or -set maxvar-) 5000 maximum variables

. use "C:\Esmeralda\Docencia\2014-15-MPII\2014-15-MPII\precasa.dta"

. regress preco area quartos

Source	SS	df	MS	Number of obs =		
Model	579971.198	2	289985.599	88	F( 2, 85) =	72.95
Residual	337883.308	85	3975.09774		Prob > F =	0.0000
Total	917854.506	87	10550.0518		R-squared =	0.6319
					Adj R-squared =	0.6232
					Root MSE =	63.048

	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
preco						
area	1.383606	.1489435	9.29	0.000	1.087467	1.679746
quartos	15.12134	9.488598	1.59	0.115	-3.744538	33.98721
_cons	-19.2855	31.04753	-0.62	0.536	-81.0163	42.4453

Review

#	Command	_rc
1	use "C:\Esmeralda\Docenci...	
2	regress preco area quartos	

Variables

Variable	Label
preco	\$1000s
quartos	número
area	m2
lote	m2

Command

# Output R

Modelo estimado:

$$\widehat{\text{preço}} = -19.286 + 1.3836 \text{ area} + 15.121 \text{ quartos}$$

Call:

```
lm(formula = preço ~ area + quartos, data = dta)
```

Residuals:

	Min	1Q	Median	3Q	Max
	-128.056	-42.814	-7.128	32.466	229.645

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	-19.2855	31.0475	-0.621	0.536
Area	1.3836	0.1489	9.289	1.4e-14 ***
quartos	15.1213	9.4886	1.594	0.115

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 63.05 on 85 degrees of freedom

**Multiple R-squared: 0.6319, Adjusted R-squared: 0.6232**

F-statistic: 72.95 on 2 and 85 DF, p-value: < 2.2e-16



# Interpretação dos coeficientes da regressão

- A interpretação do modelo é geralmente feita em termos marginais, isto é, avaliando a reação do valor esperado condicional de  $y$  dado  $\mathbf{x}$ ,  $E(y|\mathbf{x})$ , a uma variação da variável explicativa  $x_j$ , tudo o resto constante (o *ceteris paribus*)
- Em muitas situações este impacto está diretamente relacionado com o coeficiente  $\beta_j$  associado com a variável explicativa  $x_j$  mas é não sempre caso. Por exemplo se o modelo for  $E(y|x) = \beta_0 + \beta_1 x + \beta_2 x^2$  o impacto de uma variação de  $x$  no valor esperado condicionado será função de  $\beta_1$ , de  $\beta_2$  e do próprio  $x \rightarrow \frac{dE(y|x)}{dx} = \beta_1 + 2\beta_2 x$
- Comece-se então pelo caso mais simples, o modelo lin-lin, onde nenhuma variável sofreu qualquer transformação.

# Caso 1: Modelo lin-lin

Modelo linear sem transformação das variáveis,

$$E(y|\mathbf{x}) = \beta_0 + \beta_1 x_1 + \cdots + \beta_k x_k$$

Tem-se que

$$\Delta x_j = 1 \rightarrow \Delta E(y|\mathbf{x}) = \beta_j, \textit{ ceteris paribus}$$

A dedução é imediata e pode ser ilustrada para  $j = 1$ .

$$E(y|\mathbf{x}) = \beta_0 + \beta_1 x_1 + \cdots + \beta_k x_k$$

$$E(y|\mathbf{x}^*) = \beta_0 + \beta_1 (x_1 + 1) + \cdots + \beta_k x_k = E(y|\mathbf{x}) + \beta_1$$

com  $\mathbf{x}^* = (x_1 + 1, x_2, \dots, x_k) \rightarrow \textit{ ceteris paribus}$

e  $\Delta E(y|\mathbf{x}) = E(y|\mathbf{x}^*) - E(y|\mathbf{x})$

Se quer  $x_1$  quer  $x_2$  variarem de uma unidade:

$$\Delta x_1 = \Delta x_2 = 1 \rightarrow \Delta E(y|\mathbf{x}) = \beta_1 \Delta x_1 + \beta_2 \Delta x_2 = \beta_1 + \beta_2, \textit{ ceteris paribus}$$

**Exemplo:** Considere o modelo

$$preço = \beta_0 + \beta_1 area + \beta_2 quartos + u$$

onde o **preço de uma casa**, em milhares de dólares, depende da **área** (m<sup>2</sup>) e do **número de quartos** (dados disponíveis no FENIX).

Estimou-se

$$\widehat{preço} = -19.286 + 1.384 area + 15.121 quartos$$

**Admitindo tudo o resto constante:**

- por cada m<sup>2</sup> adicional (variação unitária de área), é de esperar que o preço esperado da casa aumente 1384 dólares;
- por cada quarto adicional (variação unitária de quartos) é de esperar que o preço esperado da casa aumente 15121 dólares.

# Modelo lin-lin: exemplo

Pode também analisar-se o impacto da variação simultânea das 2 variáveis explicativas.

o aumento estimado no preço esperado pelo acréscimo de um quarto que aumenta a área da casa em 13 m<sup>2</sup> é dado por

$$1.384\Delta area + 15.121\Delta quartos = 1.384 \times 13 + 15.121 \times 1$$

ou seja 33.113 milhares de dólares

Tal como o modelo foi formalizado (lin-lin), as variações são todas em termos absolutos e não em termos relativos.

# Transformar variáveis?

Em muitas situações práticas, pode tornar-se vantajoso formalizar o modelo de regressão linear depois de transformar uma ou mais variáveis (ou introduzindo termos de ordem superior nas variáveis  $x_j$  como por exemplo  $x_j^2$ ).

Flexibiliza-se assim o modelo que se ajusta a mais situações. No exemplo anterior

$$\widehat{\text{preço}} = -19.286 + 1.384 \text{ area} + 15.121 \text{quartos}$$


estamos a impôr que um acréscimo de 10 m<sup>2</sup> de área tenha sempre o mesmo efeito no preço independentemente da área do imóvel o que pode não corresponder à realidade.

As transformações mais correntes passam por logaritmizar o  $y$  e/ou uma ou mais variáveis explicativas

# Transformar variáveis?

Um exemplo ajuda a perceber a situação:

Depois de logaritmizar a variável  $y$  existe uma melhoria muito significativa do ajustamento



**Esquerda** (antes de transformar  $y$ )

Nuvem de pontos

Modelo ajustado OLS (vermelho)

· Utilizando o modelo com log (verde)

**Direita** ( $y$  foi logaritmizado)

Nuvem de pontos

Modelo ajustado OLS (verde)

Antes de avançar na interpretação dos coeficientes, duas observações:

1. A função  $\ln(w)$  apenas é definida para  $w > 0$ , por isso **não poderá ser aplicada a variáveis que assumam valores negativos ou nulos;**
2. A taxa de crescimento de uma variável  $w$  é dada por  $\frac{\Delta w}{w} = \frac{w^* - w}{w}$ , sendo  $w$  o valor inicial e  $w^* = w + \Delta w$  o valor depois da variação  $\Delta w$ . Quando  $\frac{\Delta w}{w}$  é pequeno,

$$\frac{\Delta w}{w} \cong \ln(w + \Delta w) - \ln(w)$$

Exemplo:  $w = 100$  e  $\Delta w = 1$ ,  $\frac{\Delta w}{w} = \frac{101-100}{100} = 0.01$  (tx cresc. de 1%) e

$$\ln(100 + 1) - \ln(100) = 0.00995$$

## Caso 2: Modelo log-lin

A variável  $y$  foi logaritmizada mas não a variável  $x$

$$E(\ln(y)|\mathbf{x}) = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k$$

ou 
$$\ln(y) = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + u$$

Modelo estimado:  $\widehat{\ln y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \dots + \hat{\beta}_k x_k$

Em termos diretos,  $\Delta x_j = 1 \rightarrow \Delta \widehat{\ln y} = \hat{\beta}_j$  mas o interesse reside em  $\hat{y}$  e não em  $\widehat{\ln y}$ .

Aplicando o resultado visto anteriormente vem

$$\Delta x_j = 1 \rightarrow \% \Delta \hat{y} \cong 100 \hat{\beta}_j \%, \text{ ceteris paribus}$$



## Caso 2: Modelo log-lin

Exemplificando para  $\Delta x_1 = 1$  (a que corresponde  $\hat{y}^* = \hat{y} + \Delta \hat{y}$ ),

Modelo inicial:  $\widehat{\ln y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \dots + \hat{\beta}_k x_k$

Modelo pós-incremento  $\widehat{\ln y^*} = \hat{\beta}_0 + \hat{\beta}_1 (x_1 + 1) + \dots + \hat{\beta}_k x_k$   
 $= \widehat{\ln y} + \hat{\beta}_1$   
 $\widehat{\ln y^*} - \widehat{\ln y} = \hat{\beta}_1 \cong \frac{\Delta \hat{y}}{\hat{y}}$

Logo  $\% \Delta \hat{y} = 100 \hat{\beta}_1 \%$  representando por  $\% \Delta y$  a variação percentual de  $\hat{y}$

# Modelo log-lin: exemplo

**Exemplo:** Retomem-se os dados anteriores e considere-se agora o modelo alternativo que originou

$$\ln \widehat{\text{preço}} = 4.766 + 0.0041 \textit{ area} + 0.0286 \textit{ quartos}$$

Admitindo tudo o resto constante:

- Um aumento de 1 m<sup>2</sup> na área origina um acréscimo de aproximadamente 0.41% no preço esperado da casa
- por cada quarto adicional, o preço esperado das casas aumenta aproximadamente 2.86%

## Caso 3: modelo lin-log

A variável  $x_1$  foi logaritmizada mas não a variável  $y$

$$E(y | \mathbf{x}) = \beta_0 + \beta_1 \ln(x_1) + \dots + \beta_k x_k$$

ou 
$$y = \beta_0 + \beta_1 \ln x_1 + \dots + \beta_k x_k + u$$

Modelo estimado: 
$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 \ln x_1 + \dots + \hat{\beta}_k x_k$$

Modelo pós-incremento 
$$\widehat{y}^* = \hat{\beta}_0 + \hat{\beta}_1 \ln(x_1 + 1) + \dots + \hat{\beta}_k x_k$$

$$\Delta \hat{y} = \widehat{y}^* - \hat{y} = \hat{\beta}_1 (\ln(x_1 + 1) - \ln x_1) \cong \hat{\beta}_1 \frac{\Delta x_1}{x_1}$$

Logo  $\% \Delta x_1 = 1 \rightarrow \Delta \hat{y} = \frac{\hat{\beta}_1}{100}$ , *ceteris paribus*

Nota: como é evidente, esta dedução aplica-se para qualquer  $x_j$

# Modelo lin-log: exemplo

**Exemplo:** considere um novo modelo alternativo para o mesmo problema

$$\widehat{\text{preço}} = -1153.7 + 265.0 \ln(\text{area}) + 19.63 \text{ quartos}$$

Admitindo tudo o resto constante:

- uma variação da área de 1% gera um aumento no preço esperado das casas de aproximadamente 2.65 milhares de dólares
- Como a função  $\ln(\cdot)$  apenas é definida para valores positivos das variáveis e nada impede que se tenha  $\text{quartos} = 0$  não se logaritimizou a variável.
- Este modelo é menos utilizado do que os outros

## Caso 4: modelo log-log

Quer a variável  $y$ , quer a variável  $x$  foram logaritmizadas

$$E(\ln y | \mathbf{x}) = \beta_0 + \beta_1 \ln(x_1) + \dots + \beta_k x_k$$

ou 
$$\ln y = \beta_0 + \beta_1 \ln x_1 + \dots + \beta_k x_k + u$$

Modelo estimado: 
$$\widehat{\ln y} = \hat{\beta}_0 + \hat{\beta}_1 \ln x_1 + \dots + \hat{\beta}_k x_k$$

Modelo pós-incremento 
$$\widehat{\ln y^*} = \hat{\beta}_0 + \hat{\beta}_1 \ln(x_1 + 1) + \dots + \hat{\beta}_k x_k$$

$$\begin{aligned} \text{Logo } \widehat{\ln y^*} - \widehat{\ln y} &= \hat{\beta}_1 (\ln(x_1 + 1) - \ln x_1) \\ \% \Delta \hat{y} &\cong \hat{\beta}_1 \% \Delta x_1 \end{aligned}$$

Em geral,  $\% \Delta x_j = 1 \rightarrow \% \Delta \hat{y} \cong \beta_j \%$ , *ceteris paribus*

## Caso 4: Modelo log-log Exemplo

**Exemplo:** considere-se agora o modelo

$$\ln(\widehat{\text{preço}}) = 1.289 + 0.810 \ln(\text{area}) + 0.038 \text{ quartos}$$

Admitindo tudo o resto constante:

- uma variação da área de 1% gera um aumento no preço esperado das casas de aproximadamente 0.810%
- por cada quarto adicional, o preço esperado das casas aumenta aproximadamente 3.8%

## Quadro síntese: Table 2.3 Wooldridge

$y^*$	$x^*$	Interpretação de $\beta_j$
$y$	$x_j$	$\Delta y = \beta_j \Delta x_j$
$y$	$\ln x_j$	$\Delta y = (\beta_j / 100) \% \Delta x_j$
$\ln y$	$x_j$	$\% \Delta y = (100 \beta_j) \Delta x_j$
$\ln y$	$\ln x_j$	$\% \Delta y = \beta_j \Delta x_j$

½ elasticidade constante  
elasticidade constante

# Aprofundando a interpretação dos $\hat{\beta}_j$

Modelo:  $y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + u$

Modelo estimado:  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \dots + \hat{\beta}_k x_k$  de resíduos  $\hat{u}_i$

$\hat{\beta}_j$  é o elemento  $j$  de  $\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$

Vamos agora analisar 2 pontos:

- Interpretação “Partialling out” de  $\hat{\beta}_j$
- O que acontece a  $\hat{\beta}_j$  quando se acrescenta (ou se elimina) uma das (outras) variáveis explicativas



# Efeito *partially out*

$\hat{\beta}_j$  vai medir o **efeito parcial** da variável  $x_j$  depois de considerado o efeito das restantes variáveis explicativas o que é diferente do efeito marginal que se obteria com uma regressão simples.

O teorema de Frisch-Waugh fundamenta este ponto já que prova que o  $\hat{\beta}_j$  que se obtém no MRLM é o mesmo do que aquele que se obteria numa regressão linear simples de  $y$  em  $r_j$ , resíduos da regressão de  $x_j$  nas restantes variáveis explicativas.

O efeito “*partially out*” consiste em retirar de  $x_j$  aquilo que é “comum” com as restantes variáveis explicativas (por isso se tiram os resíduos da regressão auxiliar) antes de proceder a regressão com  $y$ .

# Efeito *partially out*

Modelo:  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \dots + \hat{\beta}_k x_k$

Modelo auxiliar:  $x_j = \hat{\alpha}_0 + \hat{\alpha}_1 x_1 + \dots + \hat{\alpha}_k x_k + \hat{r}_j$  (todas menos o  $x_j$ )

RL simples:  $\hat{y} = \hat{\gamma} + \hat{\beta}_j \hat{r}_j$

**Teorema de Frisch-Waugh:**

$$\hat{\beta}_j = \frac{\sum_{i=1}^n \hat{r}_{ij} y_i}{\sum_{i=1}^n \hat{r}_{ij}^2}, j = 1, 2, \dots, k$$

onde  $\hat{r}_{ij}$  são os resíduos da regressão de  $x_{ij}$  nas restantes variáveis explicativas  $x_{i1}, x_{i2}, \dots, x_{ik}$  (todas menos o  $x_{ij}$ ). O  $\hat{\beta}_j$  que se obtém é o estimador dos MQ que se obtém na regressão (com termo independente) de  $y_i$  em  $\hat{r}_{ij}$ .

Recorda-se que a expressão obtida para  $\hat{\beta}_j$  é o estimador OLS na regressão simples.

# Teorema de Frisch-Waugh - ilustração

A demonstração do teorema de Frisch-Waugh encontra-se em anexo. Vamos apenas ver uma ilustração.

Retome-se o exemplo e estime-se a regressão de  $area_i$  em  $quartos_i$

$$\widehat{preço} = -19.286 + 1.384 \textit{ area} + 15.121 \textit{ quartos}$$

Pode obter-se  $\hat{\beta}_1$  fazendo:

Regressão de  $area$  em  $quartos$  designando por  $\hat{r}_1$  os resíduos desta regressão

$$\widehat{area} = -19.286 + 33.899 \textit{ quartos}$$

Regressão de  $preço$  em  $\hat{r}_1$

$$\widehat{preço} = 293.546 + 1.384 \hat{r}_1$$

# Teorema de Frisch-Waugh - ilustração

## Regressão original

$$\widehat{preço} = -19.286 + \mathbf{1.3836} \textit{ area} + 15.121 \textit{ quartos}$$

SUMMARY OUTPUT						
Regression Statistics						
Multiple R	0.794906945					
R Square	0.63187705					
Adjusted R Square	0.623215334					
Standard Error	63.04837628					
Observations	88					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	2	579971.1994	289985.5997	72.95055817	3.58672E-19	
Residual	85	337883.3088	3975.097751			
Total	87	917854.5083				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	-19.28550028	31.0475285	-0.621160563	0.536156232	-81.0163048	42.44530424
area(m2)	1.38360615	0.148943494	9.289470184	1.40049E-14	1.08746658	1.67974572
quartos	15.12133684	9.488597692	1.593632413	0.114730383	-3.744537442	33.98721112

# Teorema de Frisch-Waugh - ilustração

1ª regressão auxiliar: *area* como função de *quartos*

$$\widehat{area} = 66.1435 + 33.8993quartos$$

Os  $\hat{r}_{i1}$  serão os resíduos desta regressão

SUMMARY OUTPUT						
Regression Statistics						
Multiple R	0.532120204					
R Square	0.283151911					
Adjusted R Square	0.274816468					
Standard Error	45.64604375					
Observations	88					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	1	70777.80685	70777.80685	33.96963003	9.52941E-08	
Residual	86	179186.2727	2083.56131			
Total	87	249964.0795				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	66.14354244	21.31632029	3.102953114	0.002592652	23.76810017	108.5189847
quartos	33.89926199	5.816273698	5.828347109	9.52941E-08	22.33689256	45.46163143

# Teorema de Frisch-Waugh - ilustração

2ª regressão auxiliar *preço* como função de  $\hat{r}_1$  (resid)  
 $\widehat{preço} = 293.546 + 1.3836 \hat{r}_1$

SUMMARY OUTPUT						
Regression Statistics						
Multiple R	0.611333125					
R Square	0.37372819					
Adjusted R Square	0.36644596					
Standard Error	81.75590471					
Observations	88					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	1	343028.1042	343028.1042	51.32056696	2.5121E-10	
Residual	86	574826.4041	6684.027955			
Total	87	917854.5083				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	293.5460341	8.715208725	33.68204289	2.57951E-51	276.2207726	310.8712956
resid	1.38360615	0.193137569	7.163837446	2.5121E-10	0.99966137	1.76755093

# Efeito da adição de uma variável

Quando se acrescenta uma variável explicativa no modelo, os coeficientes das restantes variáveis alteram-se a não ser em dois casos muito especiais:

- O novo regressor é ortogonal em relação a qualquer dos outros
- O impacto do novo regressor é nulo

Claro que estas conclusões também são válidas (depois de adaptadas) quando se trata da eliminação de uma variável explicativa.

# Efeito da adição de uma variável

Este ponto torna-se claro ao mostrar que (ver Wooldridge ou demonstração em anexo)

$$\tilde{\beta}_j = \hat{\beta}_j + \hat{\beta}_r \tilde{\delta}_j \quad j, r = 1, 2, \dots, k \text{ e } r \neq j$$

$\hat{\beta}_j$  coeficiente de  $x_j$  na regressão de  $y$  em  $\mathbf{x} = (x_1, x_2, \dots, x_k)$ .

Inclui todas as variáveis explicativas

$\tilde{\beta}_j$  coeficiente de  $x_j$  na regressão de  $y$  em  $\mathbf{x}$  com exceção de  $x_r$ .

$\tilde{\delta}_j$  coeficiente de  $x_j$  na regressão de  $x_r$  nas restantes variáveis explicativas, isto é,  $\mathbf{x}$  com exceção de  $x_r$ .

Logo,  $\tilde{\beta}_j = \hat{\beta}_j$  vai implicar  $\hat{\beta}_r = 0$  (a variável  $x_r$  não tem impacto em  $y$ ) ou  $\tilde{\delta}_j = 0$  (ortogonalidade entre  $x_r$  e  $x_j$ )



# Efeito da adição de uma variável - ilust

Exemplo (dados no Wooldridge – wage1)

Modelo: salário/hora em dolares; educação, tenure (nº anos na empresa) e exper (experiência profissional) em anos; female=1 se mulher e 0 se homem.

$$\widehat{wage.h} = -0.84503 + \mathbf{0.53799}educ + 0.16441 tenure - 1.78839 female$$

**Qual o efeito no coeficiente de *educ* ao introduzir a variável *exper*?**

Em termos práticos estima-se uma nova regressão

$$\widehat{wage.h} = -1.56794 + \mathbf{0.57150}educ + 0.14101 tenure - 1.81085 female + 0.02539 exper$$

$$\text{E calcula-se } \hat{\beta}_1 - \tilde{\beta}_1 = 0.57150 - 0.53799 = 0.03351$$

Para verificar o resultado teórico, estima-se um terceira regressão

$$\widehat{exper} = 28.4654 - \mathbf{1.31952}educ + 0.92169 tenure + 0.88433 female$$

$$\text{e calcula-se } -\hat{\beta}_4 \tilde{\delta}_1 = -0.02539 \times (-1.31952) = 0.03350 \text{ (arredondamento)}$$

A variação (relativamente fraca) fica-se a dever ao efeito parcial de *exper* no salario (fraco) mas também no efeito parcial de *educ* em *exper* (mais forte).

# Efeito da adição de uma variável - ilust

$$\widehat{wage.h} = -0.84503 + \mathbf{0.53799} educ + 0.16441 tenure - 1.78839 female$$

SUMMARY OUTPUT		wage.h				
Regression Statistics						
Multiple R	0.598042764					
R Square	0.357655148					
Adjusted R Square	0.353963511					
Standard Error	2.968369417					
Observations	526					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	3	2560.959037	853.6530124	96.88253196	7.36418E-50	
Residual	522	4599.455273	8.811216998			
Total	525	7160.41431				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	-0.845034444	0.647737253	-1.30459448	0.192605839	-2.117526547	0.427457658
educ.years	0.537994321	0.047087329	11.42545852	3.87633E-27	0.445490372	0.63049827
tenure.years	0.164412254	0.018345337	8.96207322	5.6557E-18	0.128372492	0.200452016
female	-1.788393867	0.265593604	-6.733572799	4.377E-11	-2.310157533	-1.266630201

# Efeito da adição de uma variável - ilust

$$\widehat{wage.h} = -1.56794 + \mathbf{0.57150} educ + 0.14101 tenure - 1.81085 female + 0.02539 exper$$

SUMMARY OUTPUT		wage.h				
Regression Statistics						
Multiple R	0.602943893					
R Square	0.363541338					
Adjusted R Square	0.358654899					
Standard Error	2.957571925					
Observations	526					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	4	2603.106599	650.7766497	74.39801215	7.2956E-50	
Residual	521	4557.307712	8.747231692			
Total	525	7160.41431				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	-1.567938772	0.724551117	-2.164014016	0.030916969	-2.991339514	-0.14453803
educ.years	0.571504775	0.049337316	11.58362113	9.09319E-28	0.474580251	0.668429299
tenure.years	0.141005064	0.021161685	6.663224735	6.82937E-11	0.099432347	0.182577781
female	-1.810852171	0.264825211	-6.837914575	2.25707E-11	-2.331108636	-1.290595707
exper.years	0.025395866	0.011569434	2.195082824	0.028598072	0.002667392	0.048124339

# Efeito da adição de uma variável - ilust

$$\widehat{exper} = 28.4654 - 1.31952educ + 0.92169 tenure + 0.88433 female$$

SUMMARY OUTPUT		exper.years				
Regression Statistics						
Multiple R	0.569425246					
R Square	0.324245111					
Adjusted R Square	0.320361462					
Standard Error	11.18891453					
Observations	526					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	3	31356.72199	10452.24066	83.48981289	3.92223E-44	
Residual	522	65350.12402	125.1918085			
Total	525	96706.84601				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	28.46543377	2.44156833	11.65866768	4.46944E-28	23.66892654	33.261941
educ.years	-1.319524009	0.17749007	-7.434353978	4.3351E-13	-1.668206614	-0.970841404
tenure.years	0.921692939	0.06915056	13.32878484	4.31713E-35	0.785845354	1.057540525
female	0.88432915	1.001123417	0.883336794	0.377460959	-1.082396766	2.851055067

# Hipótese MRL 1

Para analisar a qualidade do estimador OLS e para poder definir procedimentos de inferência estatística torna-se necessário assumir um conjunto de hipóteses sobre o MRLM.

## **MLR 1** – Modelo linear nos parâmetros

O “verdadeiro” modelo na população é dado por

$$y = \beta_0 + \beta_1 x_1 + \cdots + \beta_k x_k + u$$

onde  $\beta$  é um vetor de parâmetros e  $u$  um termo de erro aleatório e não observável.

Observações:

1. Caso a relação entre  $y$  e  $x$  na população não seja esta, estariamos a utilizar um modelo “errado”
2. Tenha-se presente a **flexibilidade** “adicional” dada pela possibilidade de “**transformar**” as variáveis.

# Hipótese MRL 2

## MLR 2 – Amostra aleatória

As  $n$  observações  $(y_i, x_{i1}, x_{i2}, \dots, x_{ik})$ ,  $i = 1, 2, \dots, n$ , constituem uma amostra aleatória retirada da população.

### Observações:

1. O modelo definido na hipótese MLR 1 aplica-se a qualquer das observações,  $y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik} + u_i$ . O índice  $i$  refere-se às observações ( $i = 1, 2, \dots, n$ ) e o índice  $j$ , quando necessário, às variáveis explicativas ( $j = 1, 2, \dots, k$ ).
2. As observações serão consideradas independentes (modelo seccional).

# Hipótese MRL 3

## MLR 3 – Ausência de colinearidade perfeita

Nenhuma das variáveis explicativas pode ser combinação linear das restantes nem na amostra nem na população.

### Observações:

1. Esta hipótese destina-se a garantir que a matriz  $\mathbf{X}^T \mathbf{X}$  tem inversa, isto é, que  $(\mathbf{X}^T \mathbf{X})^{-1}$  existe. Recordar-se que  $\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T Y$  e portanto que a existência de  $(\mathbf{X}^T \mathbf{X})^{-1}$  é necessária para que o estimador  $\hat{\beta}$  exista.
2. Quando se verificar colinearidade perfeita na amostra esta será facilmente identificável no output.
3. **Importante** – Estamos a impor a **não existência de colinearidade perfeita** mas pode existir correlação entre as variáveis explicativas. Quando esta atingir valores “significativos” teremos problemas de **multicolinearidade** a serem abordados mais adiante.

# Hipótese MRL 4

## MLR 4 – Exogeneidade

$$E(u|\mathbf{x}) = 0$$

### Observações:

1. Esta hipótese é **fundamental**. O ponto essencial é que não exista correlação entre as variáveis explicativas  $x_j$  e o termo de erro  $u$ . Caso  $u$  esteja correlacionado com uma variável explicativa esta diz-se endógena e a hipótese MLR 4 ... falha!
2. Ela pode falhar por má especificação do modelo: omissão de variáveis explicativas correlacionadas com as restantes ou não transformação (quando adequada) de variáveis. Problemas a serem analisados mais adiante (eventualmente para além do programa da UC)
3. Enquanto MRL 3 diz respeito apenas às variáveis explicativas incluídas (nada tem a ver com o termo de erro  $u$ ), MLR 4 aborda as variáveis não incluídas que se encontram “representadas” por  $u$ .



# $\hat{\beta}$ estimador centrado de $\beta$

Verificadas as hipóteses MRL 1 a MLR 4, prova-se que  $E(\hat{\beta}_j) = \beta_j, j = 1, 2, \dots, k$ .

**Demonstração:**

$$\begin{aligned} Y &= \mathbf{X}\beta + U \text{ (MRL 1), } \hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T Y \text{ (MRL 2 e 3), logo} \\ \hat{\beta} &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T (\mathbf{X}\beta + U) = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{X}\beta + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T U \\ &= \beta + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T U \end{aligned}$$

Assim

$$\begin{aligned} E(\hat{\beta} | \mathbf{X}) &= E(\beta | \mathbf{X}) + E((\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T U | \mathbf{X}) = \beta + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T E(U | \mathbf{X}) \\ &= \beta \quad \text{(MRL 4)} \end{aligned}$$

$$\text{Logo } E(\hat{\beta}) = E\left(E(\hat{\beta} | \mathbf{X})\right) = E(\beta) = \beta$$

sendo, por isso  $\hat{\beta}$  um estimador centrado

# Hipótese MRL 5

## MLR 5 – Homocedasticidade

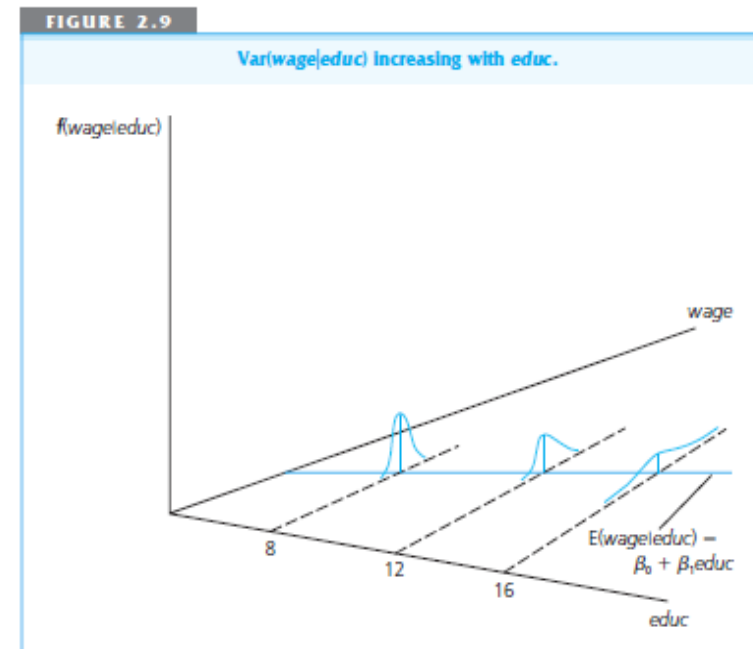
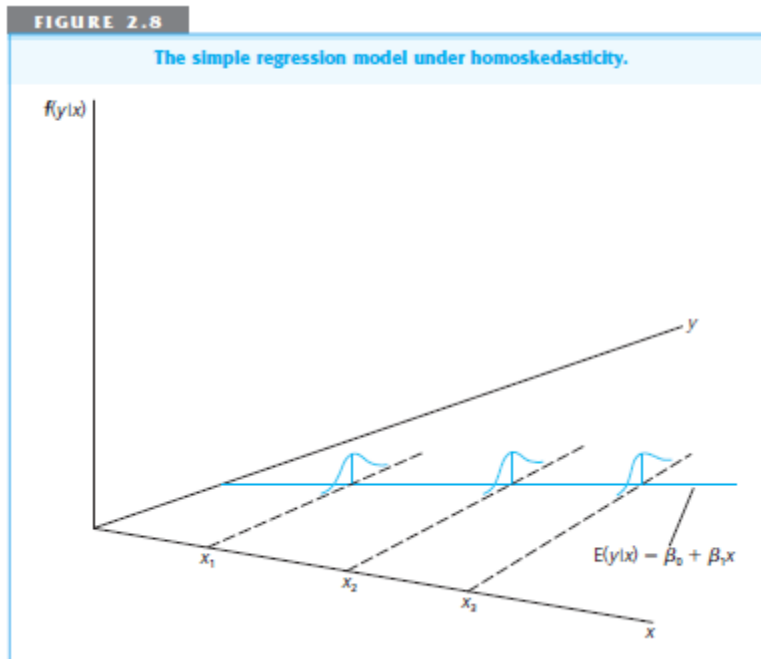
$$\text{var}(u|\mathbf{x}) = \sigma^2$$

### Observações:

1. A variância da variável residual  $u$  é constante, isto é, não depende dos valores assumidos pelas variáveis explicativas.
2. Esta hipótese nem sempre é muito realista e o seu levantamento será discutido mais adiante.
3. Tendo em conta que as observações da amostra são independentes (bastaria não correlacionadas),  $\text{var}(U|\mathbf{X}) = \sigma^2 I$ , isto é,

$$\text{var}(u_i|\mathbf{X}_{i.}) = \sigma^2 \text{ e } \text{cov}(u_i, u_j|\mathbf{X}) = 0, i, j = 1, 2, \dots, n, i \neq j$$

# Hipótese MRL 5 - ilustração



# Matriz das var/cov do estimador OLS

Recordando-se que  $\hat{\beta} = \beta + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T U$  (slide 5 desta série) e que  $\text{var}(U|\mathbf{X}) = \sigma^2 I$ , pode-se obter a matriz de variâncias e covariâncias de  $\hat{\beta}$ .

$$\begin{aligned}\text{var}(\hat{\beta}|\mathbf{X}) &= \text{var}[(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T U|\mathbf{X}] \quad (\beta \text{ é não aleatório}) \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \text{var}(U|\mathbf{X}) \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T (\sigma^2 I) \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \\ &= \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \\ &= \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1}\end{aligned}$$

Como  $\sigma^2$  é um parâmetro desconhecido,  $\text{var}(\hat{\beta}|\mathbf{X})$  será, ela também desconhecida. Para estimar  $\text{var}(\hat{\beta}|\mathbf{X})$ , matriz simétrica de dimensão  $((k + 1) \times (k + 1))$ , bastará estimar  $\sigma^2$  uma vez que a matriz  $\mathbf{X}$  é observável.

# Matriz das var/cov do estimador OLS

A variância condicionada de um dado  $\hat{\beta}_j$ ,  $j = 1, 2, \dots, k$ , que se designa por  $\sigma_{\hat{\beta}_j}^2$ , é dada pelo elemento  $(j, j)$  na diagonal principal da matriz  $\sigma^2(\mathbf{X}^T \mathbf{X})^{-1}$ , enquanto a covariância condicionada entre  $\hat{\beta}_i$  e  $\hat{\beta}_r$  será dada pelo elemento  $(i, r)$  da matriz ou pelo elemento  $(r, i)$  já que  $cov(\hat{\beta}_i, \hat{\beta}_r) = cov(\hat{\beta}_r, \hat{\beta}_i)$ .

$$var(\hat{\beta}|\mathbf{X}) = \begin{bmatrix} var(\hat{\beta}_0|\mathbf{X}) & cov(\hat{\beta}_0, \hat{\beta}_1|\mathbf{X}) & \dots \\ cov(\hat{\beta}_1, \hat{\beta}_0|\mathbf{X}) & var(\hat{\beta}_1|\mathbf{X}) & \dots \\ \dots & \dots & \dots \\ cov(\hat{\beta}_k, \hat{\beta}_0|\mathbf{X}) & cov(\hat{\beta}_k, \hat{\beta}_1|\mathbf{X}) & \dots \end{bmatrix}$$

Cada elemento desta matriz é dado pelo produto de  $\sigma^2$  (desconhecido) pelo correspondente elemento da matriz  $(\mathbf{X}^T \mathbf{X})^{-1}$

# Estimação de $\sigma^2$

Para estimar  $\sigma^2$  utiliza-se

$$\hat{\sigma}^2 = \frac{\sum \hat{u}_i^2}{n - k - 1} = \frac{\hat{U}^T \hat{U}}{n - k - 1} = MSE$$

que é estimador **centrado** de  $\sigma^2$ .

**Observação:**  $\hat{\sigma}$  é designado por **erro padrão da regressão**.

Porquê este estimador?

Sendo  $\sigma^2 = \text{var}(u_i | \mathbf{x})$  a solução “natural” seria considerar a variância observada de  $u$ ,  $S_u^2 = \frac{\sum_{i=1}^n (u_i - \bar{u})^2}{n}$  ou a sua variância corrigida. Mas, não sendo  $u$  observável, tais soluções não são possíveis.

A ideia é então utilizar  $\hat{u}_i$  em vez de  $u_i$ , introduzindo-se uma compensação no denominador destinada a garantir que o estimador é centrado.

A demonstração de que  $E(\hat{\sigma}^2) = \sigma^2$  está fora do âmbito do curso

# Matriz estimada das var/cov de $\hat{\beta}$

A matriz estimada das variâncias/covariâncias condicionais de  $\hat{\beta}$  será então

$$\widehat{var}(\hat{\beta}|\mathbf{X}) = \hat{\sigma}^2 (\mathbf{X}^T \mathbf{X})^{-1} = \begin{bmatrix} \widehat{var}(\hat{\beta}_0|\mathbf{X}) & \widehat{cov}(\hat{\beta}_0, \hat{\beta}_1|\mathbf{X}) & \cdots \\ \widehat{cov}(\hat{\beta}_1, \hat{\beta}_0|\mathbf{X}) & \widehat{var}(\hat{\beta}_1|\mathbf{X}) & \cdots \\ \cdots & \cdots & \cdots \\ \widehat{cov}(\hat{\beta}_k, \hat{\beta}_0|\mathbf{X}) & \widehat{cov}(\hat{\beta}_k, \hat{\beta}_1|\mathbf{X}) & \cdots \end{bmatrix}$$

Tal como  $\hat{\sigma}$  é designado por erro padrão da regressão, define-se o erro padrão (standard error) do estimador  $\hat{\beta}_j$  como  $\hat{\sigma}_{\hat{\beta}_j} = \sqrt{\widehat{var}(\hat{\beta}_j|\mathbf{X})}$

No caso particular do MRL simples  $y = \beta_0 + \beta_1 x + u$  obtém-se

$$\hat{\sigma}_{\hat{\beta}_1}^2 = \frac{\hat{\sigma}^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

# Output Excel

Modelo estimado:

$$\widehat{preço} = -19.286 + \mathbf{1.3836} \text{ area} + 15.121 \text{ quartos}$$

Identificar:

$$\widehat{\beta} = \begin{bmatrix} -19.286 \\ 1.3836 \\ 15.121 \end{bmatrix}$$

$$\widehat{\sigma}_{\widehat{\beta}_0} = 31.048$$

$$\widehat{\sigma}_{\widehat{\beta}_1} = 0.1489$$

$$\widehat{\sigma}_{\widehat{\beta}_2} = 9.4886$$

SUMMARY OUTPUT						
Regression Statistics						
Multiple R	0.794906945					
R Square	0.63187705					
Adjusted R Square	0.623215334					
Standard Error	63.04837628					
Observations	88					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	2	579971.1994	289985.5997	72.95055817	3.58672E-19	
Residual	85	337883.3088	3975.097751			
Total	87	917854.5083				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	-19.28550028	31.0475285	-0.621160563	0.536156232	-81.0163048	42.44530424
area(m2)	1.38360615	0.148943494	9.289470184	1.40049E-14	1.08746658	1.67974572
quartos	15.12133684	9.488597692	1.593632413	0.114730383	-3.744537442	33.98721112



## Output Principal

Call:

```
lm(formula = preço ~ area + quartos, data = dta)
```

Residuals:

Min	1Q	Median	3Q	Max
-128.056	-42.814	-7.128	32.466	229.645

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	-19.2855	31.0475	-0.621	0.536
area	1.3836	0.1489	9.289	1.4e-14 ***
quartos	15.1213	9.4886	1.594	0.115

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 63.05 on 85 degrees of freedom

Multiple R-squared: 0.6319, Adjusted R-squared: 0.6232

F-statistic: 72.95 on 2 and 85 DF, p-value: < 2.2e-16

# Output adicionais R

Matriz das var/cov estimadas

```
> vcov(out1)
```

	(Intercept)	area	quartos
(Intercept)	963.949026	-1.46733923	-180.5499241
area	-1.467339	0.02218416	-0.7520268
quartos	-180.549924	-0.75202680	90.0334862

Matrizes  $X^T X$  e  $(X^T X)^{-1}$

	$X^T X$			$(X^T X)^{-1}$		
88	16465	314		0.2424969	-0.0003691	-0.0454202
16465	3330603	60838		-0.0003691	5.5808E-06	-0.0001892
314	60838	1182		-0.0454202	-0.0001892	0.0226494

# Output Views

Modelo estimado:

$$\widehat{pre\c{c}o} = -19.286 + 1.3836 \textit{ area} + 15.121 \textit{ quartos}$$

Identificar:  $R^2 = 0.6319$   $\bar{R}^2 = 0.6232$   $n = 88$   $SSR = \sum \hat{u}_i^2 = 337883.3$

$$\widehat{\beta} = \begin{bmatrix} -19.286 \\ 1.3836 \\ 15.121 \end{bmatrix}$$

Dependent Variable: PRECO				
Method: Least Squares				
Date: 03/24/20 Time: 17:00				
Sample: 1 88				
Included observations: 88				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-19.28550	31.04753	-0.621161	0.5362
AREA	1.383606	0.148943	9.289470	0.0000
QUARTOS	15.12134	9.488598	1.593632	0.1147
R-squared	0.631877	Mean dependent var		293.5460
Adjusted R-squared	0.623215	S.D. dependent var		102.7134
S.E. of regression	63.04838	Akaike info criterion		11.15918
Sum squared resid	337883.3	Schwarz criterion		11.24363
Log likelihood	-488.0038	Hannan-Quinn criter.		11.19320
F-statistic	72.95056	Durbin-Watson stat		1.857617
Prob(F-statistic)	0.000000			

# Output Eviews

Coefficient Covariance Matrix

	C	AREA_M2_	QUARTOS
C	963.9490	-1.467339	-180.5499
AREA	-1.467339	0.022184	-0.752027
QUART	-180.5499	-0.752027	90.03349

# Teorema de Gauss Markov – Estimador BLUE

Verificadas as hipóteses MRL 1 a MRL 5, prova-se (**teorema de Gauss - Markov**) que, de entre os estimadores lineares e centrados, o estimador OLS é o de menor variância, sendo assim o mais eficiente → demonstração no Wooldridge.

**Assim, o estimador OLS é BLUE** (Best Linear Unbiased Estimator)

**Best** → Menor variância

**Linear** → Cada  $\hat{\beta}_j$  é uma combinação linear dos  $y_i$ . O estimador é assim linear em  $y$ .

$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y} = \mathbf{A} \mathbf{Y}$  em que  $\mathbf{A} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$  é uma matriz  $((k + 1) \times n)$ .  $\hat{\beta}_j = \sum_{i=1}^n a_{i,j} y_i$  sendo  $a_{i,j}$  o elemento  $(i, j)$  da matriz  $\mathbf{A}$ .

**“Unbiased”** →  $E(\hat{\beta}) = \beta$  como se mostrou anteriormente.

Demonstração: ver anexo ao capítulo 3 no Wooldridge

# Multicolinearidade

Utilizando o teorema de Frisch–Waugh, é possível aprofundar a interpretação de  $var(\hat{\beta}_j|\mathbf{X})$  já que

$$var(\hat{\beta}_j|\mathbf{X}) = \frac{\sigma^2}{SST_j (1 - R_j^2)}$$

Em que  $SST_j = \sum_{i=1}^n (x_{ij} - \bar{x}_j)^2$  e  $R_j^2$  o coeficiente de determinação da regressão de  $x_j$  nas restantes variáveis explicativas. Demonstração no apêndice do Wooldridge

Ilustração com base no exemplo anterior (utilizando  $\hat{\sigma}^2$ ):

- Do modelo principal tira-se  $\hat{\sigma}_{\hat{\beta}_1} = 0.148943494$  e  $\hat{\sigma}^2 = 3975.097751$
- Da regressão auxiliar tira-se  $SST_1 = 249964.0795$  e  $R_1^2 = 0.283151911$
- Como se pode verificar,  $0.148943494^2 = \frac{3975.097751}{249964.0795 \times 0.283151911}$

$$\text{var}(\hat{\beta}_j|\mathbf{X}) = \frac{\sigma^2}{SST_j(1 - R_j^2)}$$

Comentários:

- $\sigma^2$  é a variância da variável residual. Quanto menor esta variância for, melhor o modelo e portanto menos a variabilidade dos estimadores. Note-se que este elemento, ao contrário dos outros 2, não depende de  $j$ , isto é, é comum a todos os  $\hat{\beta}_j$
- $SST_j$  é a variação total da variável  $x_j$  na amostra. Quanto maior for esta variação, menor virá a variância condicionada de  $\hat{\beta}_j$ . Note-se que como  $SST_j = \sum_{i=1}^n (x_{ij} - \bar{x}_j)^2$  uma maior dimensão da amostra origina um crescimento de  $SST_j$ .
- $R_j^2$ . Quando mais dependente estiver  $x_j$  das restantes variáveis explicativas, maior será o valor de  $R_j^2$  e conseqüentemente maior será a variância condicionada de  $\hat{\beta}_j$ . Esta componente merece uma análise mais detalhada.

# Multicolinearidade

$$\text{var}(\hat{\beta}_j | \mathbf{X}) = \frac{\sigma^2}{SST_j(1 - R_j^2)}$$

A melhor situação (que quase nunca acontece) é quando  $R_j^2 = 0$ , isto é quando  $x_j$  é ortogonal a qualquer das outras variáveis explicativas.

No extremo oposto se  $R_j^2 = 1$ , viola-se MLR 3 e  $\text{var}(\hat{\beta}_j | \mathbf{X})$  vem infinita.

A multicolinearidade surge quando  $R_j^2$  é grande, sem atingir o valor limite de 1. Neste caso, existe o perigo de  $\text{var}(\hat{\beta}_j | \mathbf{X})$  se encontrar inflacionada, embora um elevado valor de  $SST_j$  possa mitigar (parcialmente pelo menos) este problema.

De qualquer forma, o estimador continua a ser BLUE embora o estimador tenha fraca qualidade.



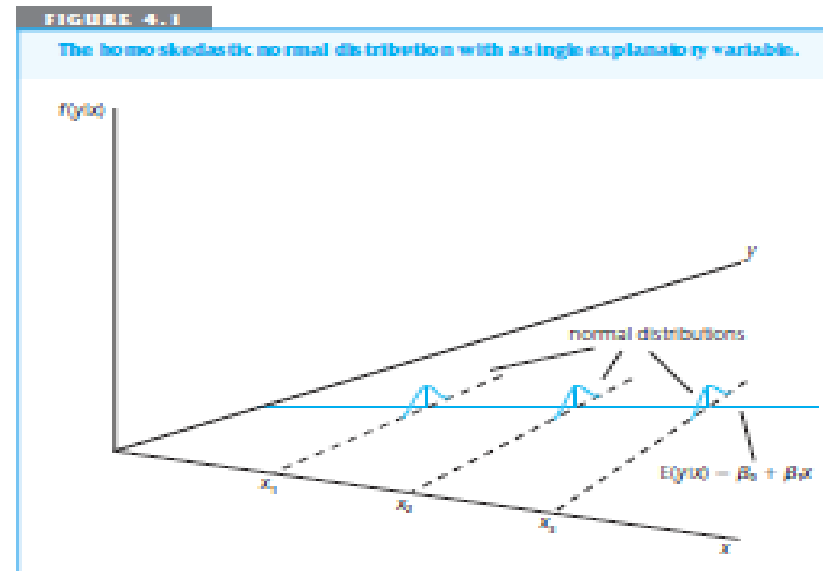
# Multicolinearidade

Possíveis soluções:

- Recolher mais informação (nem sempre funciona se esta não quebrar a excessiva dependência)
- Introduzindo alguma restrição linear entre os  $\beta_j$  que permita reformular o modelo: Que restrição? Não esquecer que se trata de algo que tem de se verificar para a população
- Eliminar alguma variável explicativa: Muito cuidado já que, como se irá ver, é muito mais grave eliminar erradamente uma variável explicativa do que incluir (erradamente) uma variável adicional.

# Hipótese MLR 6 – Distribuição normal

O termo de erro  $u$  é independente das variáveis explicativas  $x_1, x_2, \dots, x_k$  e tem **distribuição normal** de média 0 e variância  $\sigma^2$



$$y|x \sim n(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k; \sigma^2)$$

# Hipótese MLR 6

Observações:

1. Esta hipótese é bastante mais forte do que qualquer das anteriores já que, para além da distribuição normal, ela implica MLR 4 e MLR 5.

A independência entre  $u$  e  $\mathbf{x}$  implica  $E(u|\mathbf{x}) = E(u)$  e  $\text{var}(u|\mathbf{x}) = \text{var}(u)$  logo (2ª parte da hipótese)  $E(u) = 0$  e  $\text{var}(u) = \sigma^2$ .

2. O conjunto de hipóteses MLR 1 a MLR 6 é conhecido como “classical linear assumptions” (**CLM**) no quadro dos modelos seccionais.
3. No quadro das hipóteses CLM o estimador  $\hat{\beta}$  tem propriedades reforçadas: De estimador BLUE passa a ser o mais eficiente de entre os estimadores centrados (a comparação pode ser feita abrangendo estimadores não lineares)

# Distribuição por amostragem do estimador OLS

Para as  $n$  observações da amostra,

$$y_i | \mathbf{x}_i \sim n(\beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_k x_{ik}; \sigma^2)$$

Logo, em termos matriciais,  $Y | \mathbf{X} \sim N(\mathbf{X}\beta, \sigma^2 I)$ .

Como  $\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T Y$  é uma combinação linear de normais,  $\hat{\beta}$  terá distribuição normal e portanto  $\hat{\beta} \sim N(\beta, \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1})$ .

Para cada  $\hat{\beta}_j$  vem  $\hat{\beta}_j \sim N\left(\beta_j, \sigma_{\hat{\beta}_j}^2\right)$

Estandarizando  $\hat{\beta}_j$ , tem-se

$$\frac{\hat{\beta}_j - \beta_j}{\sigma_{\hat{\beta}_j}} \sim N(0,1)$$

# Inferência sobre um parâmetro $\beta_j$

A expressão  $\frac{\hat{\beta}_j - \beta_j}{\sigma_{\hat{\beta}_j}} \sim N(0,1)$  não pode ser diretamente utilizada para fazer inferência sobre  $\beta_j$  porque envolve  $\sigma_{\hat{\beta}_j}$  que é desconhecido.

A ideia é utilizar o estimador de  $\sigma_{\hat{\beta}_j}^2$  em vez do parâmetro desconhecido. Mostra-se que

$$t_j = \frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_{\hat{\beta}_j}} \sim t(n - k - 1)$$

resultado com base no qual se fará inferência (intervalos de confiança, teste de hipóteses) sobre  $\beta_j$

# Inferência sobre um parâmetro $\beta_j$

A intuição por trás do resultado  $t_j = \frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_{\hat{\beta}_j}} \sim t(n - k - 1)$  pode ser dada comparando com o procedimento adotado em Estatística 1

Estatística 1	MRLM
$Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0; 1)$	$\frac{\hat{\beta}_j - \beta_j}{\sigma_{\hat{\beta}_j}} \sim N(0,1)$
$T = \frac{\bar{X} - \mu}{S'/\sqrt{n}} \sim t(n - 1)$	$t_j = \frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_{\hat{\beta}_j}} \sim t(n - k - 1)$
Já que $\frac{(n-1)S'^2}{\sigma^2} \sim \chi^2_{(n-1)}$	E também se poderia provar que $\frac{(n-k-1)\hat{\sigma}^2}{\sigma^2} \sim \chi^2_{(n-k-1)}$

# Intervalo de confiança para $\beta_j$


Tendo em conta o rácio  $t$

$$t_j = \frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_{\hat{\beta}_j}} \sim t(n - k - 1)$$

O intervalo de confiança (com  $(1 - \alpha)100\%$  de confiança) para  $\beta_j$  vem

$$\left( \hat{\beta}_j - t_{\alpha/2} \hat{\sigma}_{\hat{\beta}_j}; \hat{\beta}_j + t_{\alpha/2} \hat{\sigma}_{\hat{\beta}_j} \right)$$

Sendo  $t_{\alpha/2}$  o quantil adequado de uma distribuição *t-Student* com  $(n - k - 1)$  graus de liberdade.



# Intervalo de confiança para $\beta_j$ - exemplo

**Exemplo:** Considere-se o exemplo que nos tem acompanhado e que originou (erro padrão por baixo de cada coeficiente)

$$\widehat{preço} = -19.286 + 1.384 \textit{ area} + 15.121 \textit{ quartos}$$

(31.046)    (0.1489)            (9.4886)

Queremos construir um IC a 95% para o impacto da área, isto é, para  $\beta_1$ .

Como  $n = 88$  e  $k = 2$  a *t-Student* terá 85 graus de liberdade.

$t_{\alpha/2} = t_{0.025} = 1.9883$  (computador). Pela tabela fazendo a média dos valores para 80 e 90 graus de liberdade dá 1.9885.

$$t_{\alpha/2} \widehat{\sigma}_{\beta_j} = 1.9883 \times 0.1489 = 0.296$$

O IC vem então  $(1.384 - 0.296; 1.384 + 0.296)$  ou seja  $(1.088; 1.680)$



# Intervalo de confiança para $\beta_j$ - exemplo

Repare-se que no Excel este IC vem dado (não esquecer o efeito arredondamento nas contas que fizemos)

## Output EXCEL

SUMMARY OUTPUT						
Regression Statistics						
Multiple R	0.794906945					
R Square	0.63187705					
Adjusted R Square	0.623215334					
Standard Error	63.04837628					
Observations	88					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	2	579971.1994	289985.5997	72.95055817	3.58672E-19	
Residual	85	337883.3088	3975.097751			
Total	87	917854.5083				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	-19.28550028	31.0475285	-0.621160563	0.536156232	-81.0163048	42.44530424
area(m2)	1.38360615	0.148943494	9.289470184	1.40049E-14	1.08746658	1.67974572
quartos	15.12133684	9.488597692	1.593632413	0.114730383	-3.744537442	33.98721112

# Teste de hipóteses para $\beta_j$

Para efetuar um teste de hipóteses sobre o parâmetro  $\beta_j$  constrói-se a estatística de teste a partir do rácio  $t$ .

$$t_j = \frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_{\hat{\beta}_j}} \sim t(n - k - 1)$$

O procedimento é em tudo semelhante ao que seguiu no capítulo do testes de hipóteses para a média de uma população normal de variância desconhecida.

Neyman-Pearson	Valor-p
Estabelecer as hipóteses em teste, $H_0$ e $H_1$	
Definir a estatística de teste (substituir $\beta_j$ pelo valor (fronteira) em $H_0$ )	
Definir $\alpha$	Calcular $t_{j,obs}$
Construir $W$ (região de rejeição)	Calcular o valor-p
Calcular $t_{j,obs}$	Decidir
Decidir	

# Teste de hipóteses para $\beta_j$ - Exemplo

**Exemplo:** Suponha-se que, no exemplo anterior, se quer testar se um acréscimo de 10 m<sup>2</sup> na área tem um impacto esperado superior a 10 mil dólares.

$$\widehat{preço} = -19.286 + 1.384 \textit{ area} + 15.121 \textit{ quartos}$$

(31.046)    (0.1489)            (9.4886)

$H_0: \beta_1 \leq 1.0$  vs  $H_1: \beta_1 > 1.0$       (10 mil dólares por 10 m<sup>2</sup>  $\leftrightarrow$  1000 dolares/m<sup>2</sup>)

Estatística teste:  $T = \frac{\widehat{\beta}_1 - 1.0}{\widehat{\sigma}_{\widehat{\beta}_1}} \sim t(85)$

N-P:  $\alpha = 0.05$  (por hip) logo  $t_\alpha = t_{0.05} = 1.663$  e  $W = \{t: t > 1.663\}$

$t_{1,obs} = \frac{1.384 - 1.0}{0.1489} = 2.579$  logo rejeita-se  $H_0$ , isto é, o impacto é sup. 10 mil dólares.

Valor-p:  $P(T \geq 2.579) = 0.0058$  e tira-se a mesma conclusão

# Significância de $x_j$

De entre os possíveis valores de  $\beta_j$ , o valor 0 tem um significado particularmente importante: **testa a significância estatística do regressor associado com  $\beta_j$ .**

O teste é então  $H_0: \beta_j = 0$  vs  $H_1: \beta_j \neq 0$

Estatística teste:  $T = \frac{\hat{\beta}_1 - 0}{\hat{\sigma}_{\hat{\beta}_1}} = \frac{\hat{\beta}_1}{\hat{\sigma}_{\hat{\beta}_1}} \sim t(n - k - 1)$

Rejeitar  $H_0$  equivale a aceitar que a variável  $x_j$  é relevante para explicar o comportamento de  $y$ . Pelo contrário, **não rejeitar  $H_0$  equivale a não rejeitar que  $x_j$  é irrelevante** para explicar o comportamento de  $y$ .

Como este teste é feito de forma rotineira para todos os regressores, o seu resultado figura nos outputs de computador.

# Significância de $x_j$ - exemplo

**Exemplo:** Retome-se o exemplo e teste-se a significância estatística dos regressores.

$$H_0: \beta_j = 0 \text{ vs } H_1: \beta_j \neq 0 \quad t_{j,obs} = \frac{\hat{\beta}_j}{\hat{\sigma}_{\hat{\beta}_j}} \quad \text{valor} - p = P(|T| \geq |t_{j,obs}|)$$

SUMMARY OUTPUT						
Regression Statistics						
Multiple R	0.794906945					
R Square	0.63187705					
Adjusted R Square	0.623215334					
Standard Error	63.04837628					
Observations	88					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	2	579971.1994	289985.5997	72.95055817	3.58672E-19	
Residual	85	337883.3088	3975.097751			
Total	87	917854.5083				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	-19.28550028	31.0475285	-0.621160563	0.536156232	-81.0163048	42.44530424
area(m2)	1.38360615	0.148943494	9.289470184	1.40049E-14	1.08746658	1.67974572
quartos	15.12133684	9.488597692	1.593632413	0.114730383	-3.744537442	33.98721112

# Significância de $x_j$ - exemplo

## Exemplo (continuação): Mesmo exemplo com output STATA

```
. regress preco area quartos
```

Source	SS	df	MS	Number of obs	=	88
Model	579971.198	2	289985.599	F( 2, 85)	=	72.95
Residual	337883.308	85	3975.09774	Prob > F	=	0.0000
Total	917854.506	87	10550.0518	R-squared	=	0.6319

Adj R-squared = 0.6232  
Root MSE = 63.048

preco	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
area	1.383606	.1489435	<b>9.29</b>	<b>0.000</b>	1.087467	1.679746
quartos	15.12134	9.488598	<b>1.59</b>	<b>0.115</b>	-3.744538	33.98721
_cons	-19.2855	31.04753	-0.62	0.536	-81.0163	42.4453

# Significância de $x_j$ - exemplo

```
. regress preco quartos area
```

Source	SS	df	MS	Number of obs =	88
Model	579971.198	2	289985.599	F( 2, 85) =	72.95
Residual	337883.308	85	3975.09774	Prob > F =	0.0000
Total	917854.506	87	10550.0518	R-squared =	0.6319

-----

				Adj R-squared =	0.6232
				Root MSE =	63.048

preco	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
quartos	15.12134	9.488598	1.59	0.115	-3.744538	33.98721
area	1.383606	.1489435	9.29	0.000	1.087467	1.679746
_cons	-19.2855	31.04753	-0.62	0.536	-81.0163	42.4453

```
. matrix list e(V)
```

```
symmetric e(V) [3,3]
```

	quartos	area	_cons
quartos	90.033486		
area	<b>-0.7520268</b>	.02218416	
_cons	-180.54992	-1.4673392	963.94902

# Teste ao sinal de um $\beta_j$

Outro caso particular que surge com alguma frequência é o de avaliar o sinal do impacto. Neste caso o teste será

**Caso 1** –  $H_0: \beta_j \leq 0$  vs  $H_1: \beta_j > 0$  ou  $H_0: \beta_j = 0$  vs  $H_1: \beta_j > 0$

**Caso 2** –  $H_0: \beta_j \geq 0$  vs  $H_1: \beta_j < 0$  ou  $H_0: \beta_j = 0$  vs  $H_1: \beta_j < 0$

Observações:

1. Os dois testes não são de todo equivalentes. O caso 1 testa um impacto positivo enquanto o caso 2 testa um impacto negativo (ver  $H_1$ ). A resposta é “afirmativa” quando se rejeita  $H_0$ .
2. Nas 2 situações a estatística de teste será  $T = \frac{\hat{\beta}_1}{\hat{\sigma}_{\hat{\beta}_1}} \sim t(n - k - 1)$
3. No 1º caso a região de rejeição é unilateral direita e no segundo caso unilateral esquerda.



# Estatística t: principais variantes

Teste à significância (individual) estatística de um regressor:

Hipóteses	$t_j$	Nota
$H_0: \beta_j = 0$ $H_1: \beta_j \neq 0$	$\frac{\hat{\beta}_j}{\hat{\sigma}_{\hat{\beta}_j}}$	Apresentado automaticamente nos output da regressão

Teste ao sinal de um coeficiente:

Hipóteses	$t_j$	Nota
$H_0: \beta_j = 0$ $H_1: \beta_j > 0$ ( $H_1: \beta_j < 0$ )	$\frac{\hat{\beta}_j}{\hat{\sigma}_{\hat{\beta}_j}}$	Região de rejeição unilateral direita (esquerda)

Teste para um valor particular de um coeficiente (c):

Hipóteses	$t_j$	Nota
$H_0: \beta_j = c$ $H_1: \beta_j \neq c$ ( $H_1: \beta_j > c$ ou $H_1: \beta_j < c$ )	$\frac{\hat{\beta}_j - c}{\hat{\sigma}_{\hat{\beta}_j}}$	Região de rejeição bilateral (unilateral à direita ou esquerda)

# Relevância prática de um regressor

Para além da significância estatística é necessário analisar a relevância prática do regressor, isto é se a variável  $x_j$  tem um impacto efetivo no comportamento de  $y$ .

Como  $t_{j,obs} = \frac{\hat{\beta}_j}{\hat{\sigma}_{\hat{\beta}_j}}$ , um valor elevado de  $|t_{j,obs}|$  que leve a uma rejeição clara de

$H_0: \beta_j = 0$  pode ter origem:

- Num valor elevado de  $|\beta_j|$  (combinado com um valor razoável de  $\hat{\sigma}_{\hat{\beta}_j}$ );
- Num valor muito pequeno de  $\hat{\sigma}_{\hat{\beta}_j}$  sem que  $|\beta_j|$  assuma um valor que seja relevante em termos práticos (o que pode ser facilitado por amostras de grande dimensão)

# Relevância prática de um regressor

## Exemplo Wooldridge – Participation Rates in 401 (k) Plans

A ideia é explicar a taxa de participação *prate* (percentagem de trabalhadores elegíveis que aderem ao plano) no plano de pensões 401 (k) em função do peso da contribuição patronal *mrate* (montante que a empresa mete no fundo por cada dólar de contribuição do trabalhador), da idade do plano *age*, e do tamanho da empresa *totemp* (nº de trabalhadores). Dados na página da UC.

O modelo estimado foi

$$\widehat{prate} = 80.29 + 5.44 \, mrate + 0.269 \, age - 0.0001297 \, totemp$$

(0.78)   (0.52)                    (0.045)                    (0.0000367)

$$n = 1534 \quad R^2 = 0.100 \quad \overline{prate} = 87.4 \quad \overline{totemp} = 3567.3$$

Como se pode verificar, rejeita-se claramente  $H_0: \beta_3 = 0$  ( $t_{3,obs} = -3.53$ ) logo *totemp* é estatisticamente significativa relevante (*p-value* = 0.00042) mas de pouca relevância prática: Para um crescimento de 10000 trabalhadores na empresa a tx de participação diminuiria de 1.297pp!

**Não olhar tanto para o valor do coeficiente mas sim este valor multiplicado pelos valores “razoáveis” da variável *x*!**

# Testes sobre uma combinação linear de coeficientes

O propósito é agora fazer inferência (IC ou TH) sobre uma combinação linear de coeficientes  $\delta = \beta_0 c_0 + \beta_1 c_1 + \dots + \beta_k c_k$ .

Observações:

1. Os  $\beta_j$  são os coeficientes do modelo que estimámos
2. Os  $c_j$  são valores pré-fixados em função do que se pretende testar.

3. Por exemplo, se no modelo

$$preço = \beta_0 + \beta_1 area + \beta_2 quartos + u$$

Se se quisesse testar se o impacto de 10 m<sup>2</sup> de área equivale ao impacto de 1 quarto definir-se-ia  $\delta = 10\beta_1 - \beta_2$  e testar-se-ia  $H_0: \delta = 0$

4. Como é óbvio este caso engloba o anterior (1 parâmetro)

# Testes sobre uma combinação linear de coeficientes

A estimação de  $\delta$  não levanta problema

$$\hat{\delta} = \hat{\beta}_0 c_0 + \hat{\beta}_1 c_1 + \cdots + \hat{\beta}_k c_k = c\hat{\beta}$$

Sendo  $c = [c_0 \quad c_1 \quad \cdots \quad c_k]$  um vetor linha e  $\hat{\beta}$  o vetor coluna dos estimadores/estimativas de  $\beta$ .

Para obter a variância do estimador  $\hat{\delta}$ , aplica-se a regra habitual para a variância de uma combinação linear de v.a., **não esquecendo as covariâncias** entre os  $\hat{\beta}_j$ . Em termos matriciais vem

$$var(\hat{\delta}) = \sigma_{\hat{\delta}}^2 = var(c\hat{\beta}) = c var(\hat{\beta})c^T = \sigma^2 c(\mathbf{X}^T \mathbf{X})^{-1} c^T$$

já que  $var(\hat{\beta}) = \sigma^2(\mathbf{X}^T \mathbf{X})^{-1}$ .

Assim das propriedades da normal vem  $\hat{\delta} \sim N(\delta, \sigma_{\hat{\delta}}^2)$

# Testes sobre uma combinação linear de coeficientes

Como  $\sigma_{\hat{\delta}}^2$  é desconhecido por não se conhecer  $\sigma^2$ , o único elemento desconhecido, aplica-se um raciocínio em tudo idêntico ao que se aplicou para  $\hat{\beta}_j$  e obtém-se

$$t_{\hat{\delta}} = \frac{\hat{\delta} - \delta}{\hat{\sigma}_{\hat{\delta}}} \sim t(n - k - 1)$$

com base no qual se fará a inferência estatística.

- IC  $(1 - \alpha)$  vem  $(\hat{\delta} - t_{\alpha/2} \hat{\sigma}_{\hat{\delta}}; \hat{\delta} + t_{\alpha/2} \hat{\sigma}_{\hat{\delta}})$
- TH – Em tudo semelhante ao que se fez para  $\hat{\beta}_j$

A dificuldade prática reside em obter  $\hat{\sigma}_{\hat{\delta}}$  quer porque muitos softwares não reportam diretamente a matriz estimada das var/cov de  $\hat{\beta}$  quer, em menor grau, por obrigar a uma conta adicional.

# Testes sobre uma combinação linear de coeficientes

Retorne-se ao exemplo

$$\widehat{preço} = -19.286 + 1.3836 \textit{ area} + 15.121 \textit{ quartos}$$
$$(31.046) \quad (0.1489) \quad (9.4886)$$

e assumamos que se queria testar se o impacto de 10 m<sup>2</sup> de área equivale ao impacto de 1 quarto.

De acordo com o que se viu define-se  $\delta = 10\beta_1 - \beta_2$  e testa-se

$H_0: \delta = 0$  vs  $H_1: \delta \neq 0$  com base na estatística de teste

$$t = \frac{\hat{\delta}}{\hat{\sigma}_{\hat{\delta}}} \sim t(88 - 2 - 1).$$

Em termos observados,  $\hat{\delta} = 10\hat{\beta}_1 - \hat{\beta}_2 = -1.285$  e

$$\hat{\sigma}_{\hat{\delta}}^2 = 10^2 \hat{\sigma}_{\hat{\beta}_1}^2 + \hat{\sigma}_{\hat{\beta}_2}^2 - 2 \times 10 \times 1 \hat{\sigma}_{\hat{\beta}_1 \hat{\beta}_2}$$

Para obter  $\hat{\sigma}_{\hat{\beta}_1 \hat{\beta}_2}$  tem de recorrer-se à matriz estimada das var/cov de  $\hat{\beta}$ . Note-se que  $\hat{\sigma}_{\hat{\beta}_1}^2 = 0.1489^2$  e  $\hat{\sigma}_{\hat{\beta}_2}^2 = 9.4886^2$ .

# Testes sobre uma combinação linear de coeficientes

Recordando a matriz apresentada anteriormente (ver tópico sobre propriedades do modelo – MLR 5)

	(Intercept)	area	quartos
(Intercept)	963.949026	-1.46733923	-180.5499241
area	-1.467339	0.02218416	-0.7520268
quartos	-180.549924	-0.75202680	90.0334862

$$\begin{aligned}\hat{\sigma}_{\hat{\delta}}^2 &= 10^2 \hat{\sigma}_{\hat{\beta}_1}^2 + \hat{\sigma}_{\hat{\beta}_2}^2 - 2 \times 10 \times 1 \hat{\sigma}_{\hat{\beta}_1 \hat{\beta}_2} \\ &= 100 \times 0.02218 + 90.033 + 20 \times 0.75203 = 107.29\end{aligned}$$

$$\text{Assim, } t_{\hat{\delta}, obs} = \frac{\hat{\delta}}{\hat{\sigma}_{\hat{\delta}}} = \frac{-1.285}{\sqrt{107.29}} = -0.124 \text{ e portanto não se rejeita } H_0 ,$$

*Valor-p=0.9015*

Vamos utilizar este exemplo para introduzir uma metodologia alternativa para efetuar o mesmo teste



# Testes sobre uma combinação linear de coeficientes

## Observação:

Neste caso  $\delta = 10\beta_1 - \beta_2 = c\beta$  com  $c = [0 \quad 10 \quad -1]$  e

$$\begin{aligned}\hat{\sigma}_{\hat{\delta}}^2 &= [0 \quad 10 \quad -1] \begin{bmatrix} 963.949 & -1.46734 & -180.550 \\ -1.4674 & 0.022184 & -0.75203 \\ -180.550 & -0.75203 & 90.0334 \end{bmatrix} \begin{bmatrix} 0 \\ 10 \\ -1 \end{bmatrix} \\ &= [-14.674 + 180.550 \quad 0.22184 + 0.75203 \quad -7.5203 - 90.0334] \begin{bmatrix} 0 \\ 10 \\ -1 \end{bmatrix} \\ &= 0 + 10 \times (0.22184 + 0.75203) + 1 \times (7.520 + 90.0334) \\ &= 9.7387 + 97.5534 = 107.2921 \\ \hat{\sigma}_{\hat{\delta}} &= 10.358\end{aligned}$$

# Testes sobre uma combinação linear de coeficientes

## Método alternativo

Temos  $\delta = 10\beta_1 - \beta_2$

Resolver em ordem a um dos  $\beta_j \rightarrow \beta_2 = 10\beta_1 - \delta$

Obter a regressão auxiliar: Substituir o  $\beta_j$  escolhido no modelo pela expressão obtida e simplificar

$$preço = \beta_0 + \beta_1 area + \beta_2 quartos + u$$

$$preço = \beta_0 + \beta_1 area + (10\beta_1 - \delta) quartos + u$$

$$preço = \beta_0 + \beta_1 area + 10\beta_1 quartos - \delta quartos + u$$

$$preço = \beta_0 + \beta_1 (area + 10quartos) - \delta quartos + u$$

$$preço = \beta_0 + \beta_1 x^* + \delta (-quartos) + u \quad \text{com } x^* = (area + 10quartos)$$

Definir a nova variável e estimar o modelo auxiliar (slide seguinte)

Fazer inferência sobre  $\delta$  a partir do output obtido para a regressão auxiliar

# Testes sobre uma combinação linear de coeficientes

## Output regressão auxiliar

SUMMARY OUTPUT						
Regression Statistics						
Multiple R	0.794906945					
R Square	0.63187705					
Adjusted R Square	0.623215334					
Standard Error	63.04837628					
Observations	88					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	2	579971.1994	289985.5997	72.95055817	3.58672E-19	
Residual	85	337883.3088	3975.097751			
Total	87	917854.5083				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	-19.28550028	31.0475285	-0.621160563	0.536156232	-81.0163048	42.44530424
$x^*$	1.38360615	0.148943494	9.289470184	1.40049E-14	1.08746658	1.67974572
quartos	-1.285275338	10.35820635	-0.124082809	0.901542671	-21.8801646	19.30961392

Repare-se que a linha de  $x^*$  referente ao parâmetro  $\hat{\beta}_1$  não se alterou em relação ao modelo inicial (*área*)

# Testes sobre uma combinação linear de coeficientes

**Exemplo:** Considere o modelo (ver o tópico relevância prática de um regressor)

$$prate = \beta_0 + \beta_1 mrate + \beta_2 age + \beta_3 totemp + u$$

- a) Escreva a regressão auxiliar para fazer inferência sobre  $\delta = 4\beta_1 - 10\beta_2$
- b) Mesma questão para  $\theta = \frac{\beta_2}{2} + 1000\beta_3$
- c) Obter um IC a 95% para  $\delta$
- d) Testar  $H_0: \delta = 0$  contra  $H_1: \delta \neq 0$

# Testes sobre uma combinação linear de coeficientes

$$prate = \beta_0 + \beta_1 mrate + \beta_2 age + \beta_3 totemp + u$$

a) Escreva a regressão auxiliar para fazer inferência sobre  $\delta = 4\beta_1 - 10\beta_2$

**Sol 1:**

$$\delta = 4\beta_1 - 10\beta_2 \text{ logo } \beta_1 = 0.25 \delta + 2.5 \beta_2$$

$$prate = \beta_0 + (0.25 \delta + 2.5 \beta_2) mrate + \beta_2 age + \beta_3 totemp + u$$

$$prate = \beta_0 + \delta (0.25 \times mrate) + \beta_2 (age + 2.5 mrate) + \beta_3 totemp + u$$

**Sol 2:**

$$\delta = 4\beta_1 - 10\beta_2 \text{ logo } \beta_2 = 0.4 \beta_1 - 0.1 \delta$$

$$prate = \beta_0 + \beta_1 mrate + (0.4 \beta_1 - 0.1 \delta) age + \beta_3 totemp + u$$

$$prate = \beta_0 + \beta_1 (mrate + 0.4 age) + \delta (-0.1 \times age) + \beta_3 totemp + u$$

**Desafio:** Estime as 2 regressões auxiliares e verifique que as linhas referentes a  $\delta$  são idênticas.

# Testes sobre uma combinação linear de coeficientes

$$prate = \beta_0 + \beta_1 mrate + \beta_2 age + \beta_3 totemp + u$$

b) Mesma questão para  $\theta = \frac{\beta_2}{2} + 1000\beta_3$

**Sol 1:**

$$\theta = \frac{\beta_2}{2} + 1000\beta_3 \text{ logo } \beta_2 = 2\theta - 2000\beta_3$$

$$prate = \beta_0 + \beta_1 mrate + (2\theta - 2000\beta_3)age + \beta_3 totemp + u$$

$$prate = \beta_0 + \beta_1 mrate + \theta(2 \times age) + \beta_3(totemp - 2000 \times age) + u$$

**Sol 2:**

$$\theta = \frac{\beta_2}{2} + 1000\beta_3 \text{ logo } \beta_3 = 0.001\theta - 0.0005\beta_2$$

$$prate = \beta_0 + \beta_1 mrate + \beta_2 age + (0.001\theta - 0.0005\beta_2) totemp + u$$

$$prate = \beta_0 + \beta_1 mrate + \beta_2 (age - 0.0005 totemp) + \theta(0.001 \times totemp) + u$$

# Testes sobre uma combinação linear de coeficientes

$$prate = \beta_0 + \beta_1 mrate + \beta_2 age + \beta_3 totemp + u$$

c) Obter um IC a 95% para  $\delta$  - sol 1

$$prate = \beta_0 + \delta (0.25 \times mrate) + \beta_2 (age + 2.5 mrate) + \beta_3 totemp + u$$

SUMMARY OUTPUT						
Regression Statistics						
Multiple R	0.315592361					
R Square	0.099598538					
Adjusted R Square	0.097833045					
Standard Error	15.87778005					
Observations	1534					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	3	42666.57348	14222.19116	56.41400708	1.37991E-34	
Residual	1530	385718.966	252.1038993			
Total	1533	428385.5394				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	80.29428539	0.777695208	103.2464706	0	78.76882403	81.81974675
0.25mrate	19.07165742	2.199785126	8.669781966	1.08405E-17	14.75674437	23.38657047
age+2.5mrate	0.269407284	0.04514857	5.967127681	2.99497E-09	0.180847655	0.357966913
totemp	-0.000129781	3.67184E-05	-3.534503198	0.000420703	-0.000201805	-5.77576E-05

d)  $H_0: \delta = 0$  contra  $H_1: \delta \neq 0$        $t_{obs} = 8.67$        $p - value \approx 0$  Rejeita-se  $H_0$

# Testes sobre $q$ combinações lineares de coeficientes

Vamos agora considerar que queremos testar várias combinações lineares de  $\beta_j$

Embora se possa continuar a considerar as 2 vias de abordagem anteriores (“matricial” ou regressão auxiliar por reparametrização da regressão original) apenas se irá desenvolver a segunda por ser bastante mais eficiente.

Apresentaremos o problema do caso mais simples para o mais geral (complicado) e utilizaremos um novo exemplo com base numa regressão envolvendo mais parâmetros



# Testes sobre $q$ combinações lineares de coeficientes

Exemplo: Vamos modelar o logaritmo do salário dos jogadores profissionais de baseball (dados de 1993 no ficheiro MLB1\_simplificado.xlsx) em função de 5 características:

- *years* – nº de anos de carreira do jogador
- *gamesyr* – nº médio de jogos que o jogador joga por ano
- *bavg* – nº médio de batting/ano
- *hrunsyr* – nº médio de *home runs* por ano
- *rbisyr* – nº médio de “runs” por ano (“runs batted in per year”)

Modelo

$$\ln \text{salary} = \beta_0 + \beta_1 \text{years} + \beta_2 \text{gamesyr} + \beta_3 \text{bavg} + \beta_4 \text{hrunsyr} + \beta_5 \text{rbisyr} + u$$

# Testes sobre $r$ combinações lineares de coeficientes

## Modelo estimado

SUMMARY OUTPUT						
Regression Statistics						
Multiple R	0.792340118					
R Square	0.627802862					
Adjusted R Square	0.622439791					
Standard Error	0.726577259					
Observations	353					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	5	308.9892282	61.79784565	117.0603271	2.93802E-72	
Residual	347	183.1863363	0.527914514			
Total	352	492.1755645				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	11.19242075	0.288822864	38.75185162	4.1871E-128	10.62435701	11.76048449
years	0.068862623	0.0121114544	5.684293499	2.7876E-08	0.045035448	0.092689799
gamesyr	0.012552112	0.002646763	4.742438528	3.08865E-06	0.007346394	0.017757829
bavg	0.000978594	0.001103509	0.886802204	0.375799595	-0.001191814	0.003149002
hrunsyr	0.014429519	0.01605698	0.898644642	0.369465108	-0.017151734	0.046010772
rbisyrr	0.01076574	0.007174962	1.50045958	0.134404707	-0.003346147	0.024877626

Olhando para o output vê-se que os 3 últimos coeficientes não são, individualmente considerados, estatisticamente significativos. Será que o mesmo se pode afirmar para o conjunto?

# Teste à significância conjunta de $q$ regressores

Considere-se, sem perda de generalidade, que se estava a testar a significância conjunta dos últimos  $r$  coeficientes. Definindo  $p = k - q$ , a hipótese em teste escreve-se:

$$H_0: \beta_{p+1} = \dots = \beta_k = 0$$

## Estratégia de teste

- Estimar o modelo incorporando a restrição definida em  $H_0$ , isto é, estimar o modelo sem considerar as variáveis  $x_{p+1}, x_{p+2}, \dots, x_k$ .
- Comparar a qualidade do modelo com restrição com a qualidade do modelo inicial (sem a restrição):
  - Se a qualidade for semelhante, pode concluir-se que as  $r$  variáveis associadas com os coeficientes em teste não acrescentam nada de significativo ao modelo e poderão ser consideradas **conjuntamente não significantes** e, eventualmente, eliminadas.
  - Se a introdução da restrição originar uma quebra de qualidade significativa, a conclusão terá de ser a oposta. As variáveis  $x_{p+1}, x_{p+2}, \dots, x_k$  são conjuntamente significantes.
- Problemas em aberto:
  - Como medir a qualidade? Utilizar a soma dos quadrados dos resíduos de cada modelo
  - Como definir a fronteira? Basearmo-nos numa estatística de teste.

## Teste à significância conjunta de $q$ regressores

$$H_0: \beta_{p+1} = \dots = \beta_k = 0 \quad \text{vs} \quad H_1: \exists \beta_j \neq 0, j = p + 1, \dots, k$$

Ou, mais simplesmente,  $H_1: H_0$  falsa

Estimar o modelo inicial com  $k$  variáveis explicativas  $\rightarrow SSR$

Estimar o modelo com  $q$  restrições ( $k - q$  var expli)  $\rightarrow SSR_*$  ( $q$  restrições)

Mostra-se que

$$F = \frac{(SSR_* - SSR)/q}{SSR/(n - k - 1)} \sim F(q, n - k - 1)$$

Por razões óbvias, a região de rejeição situar-se-á na cauda direita da distribuição

## Teste à significância conjunta de $q$ regressores

Como neste caso a variável  $y$  é a mesma nos 2 modelos, pode mostrar-se que  $\frac{(SSR_* - SSR)/q}{SSR/(n-k-1)} = \frac{(R^2 - R_*^2)/q}{(1-R^2)/(n-k-1)}$  e portanto, de forma equivalente, tem-se

$$F = \frac{(R^2 - R_*^2)/q}{(1 - R^2)/(n - k - 1)} \sim F(q, n - k - 1)$$

Sendo o “\*” referente ao modelo com restrições.

Para mostrar a igualdade fazer  $R^2 = 1 - SSR/SST$  sendo  $SST$  o mesmo nos 2 modelos ( a variação total apenas depende de  $y$ ).

$$R^2 = 1 - SSR/SST \text{ logo } SSR = (1 - R^2) SST$$
$$\frac{(SSR_* - SSR)}{SSR} = \frac{((1 - R_*^2)SST - (1 - R^2)SST)}{(1 - R^2)SST} = \frac{(1 - R_*^2) - (1 - R^2)}{(1 - R^2)} = \frac{R^2 - R_*^2}{(1 - R^2)}$$

# Teste à significância conjunta de $q$ regressores

Exemplo:  $H_0: \beta_3 = \beta_4 = \beta_5 = 0$  vs  $H_1: H_0$  falsa (pelo menos um dos  $\beta \neq 0$ )

Modelo com a restrição

SUMMARY OUTPUT						
Regression Statistics						
Multiple R	0.772704072					
R Square	0.597071582					
Adjusted R Square	0.594769134					
Standard Error	0.752731258					
Observations	353					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	2	293.8640431	146.9320216	259.3203218	8.2202E-70	
Residual	350	198.3115214	0.566604347			
Total	352	492.1755645				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	11.22380399	0.108312013	103.6247386	9.966E-265	11.01077971	11.43682826
years	0.071317962	0.012505011	5.703150453	2.50422E-08	0.046723543	0.095912381
gamesyr	0.02017448	0.00134287	15.02340897	1.01913E-39	0.017533371	0.022815589

$$F_{obs} = \frac{(198.311 - 183.186)/3}{183.186/(353 - 1 - 5)} = 9.55 \quad p\text{-value} = P(F_{3;347} \geq 9.55) \approx 0 \quad (4.47E - 06)$$

$$\text{Ou } F_{obs} = \frac{(0.627803 - 0.597072)/3}{(1 - 0.627803)/(353 - 1 - 5)} = 9.55 \quad F_{0.05} = 2.6306$$

Rejeita-se  $H_0$  logo as avariáveis são conjuntamente significantes -> Multicolinearidade

# Teste à significância conjunta de *todos* os regressores

## Hipóteses em teste

$H_0: \beta_1 = \dots = \beta_k = 0$  vs  $H_1: H_0$  falsa (pelo menos um dos  $\beta \neq 0$ )

Utiliza-se a estratégia de teste vista para o caso anterior.

O modelo com restrições não precisa de ser estimado já que não incorporando nenhum regressor teremos:  $R_*^2 = 0$ ,  $SSR_* = SST$  e  $SSE_* = 0$ .

A estatística de teste será então  $F = \frac{(SST-SSR)/k}{SSR/(n-k-1)} \sim F(k, n - k - 1)$  ou

$$F = \frac{R^2/k}{(1-R^2)/(n-k-1)} = \frac{R^2}{1-R^2} \frac{n-k-1}{k} \sim F(k, n - k - 1)$$

Como este teste (teste à significância global da regressão) é feito de forma rotineira ela está incluído em todos os output de computador.

# Testes sobre várias combinações lineares – caso geral

A metodologia de teste que se apresentou pode ser estendida para qualquer sistema de restrições lineares.

Para tal:

- Definir o sistema de restrições que se quer testar
- Resolver o sistema em ordem a um sub-conjunto de  $\beta_j$
- Definir a regressão auxiliar e estimá-la
- Calcular  $F_{obs}$  e realizar o teste (utilizando o *valor-p* ou valor crítico)

**Nota importante:** Caso a variável dependente da regressão auxiliar seja diferente da variável dependente da regressão original não se pode utilizar o resultado baseado no  $R^2$ .



# Testes sobre várias combinações lineares – caso geral

Exemplo: Considere-se o exemplo anterior e admita-se que se quer testar

$$H_0: \begin{cases} \beta_1 = 0.1 \\ \beta_4 - \beta_5 = 0 \end{cases} \text{ vs } H_1: H_0 \text{ falsa}$$

- Resolver o sistema

$$\begin{cases} \beta_1 = 0.1 \\ \beta_4 - \beta_5 = 0 \end{cases} \Leftrightarrow \begin{cases} \beta_1 = 0.1 \\ \beta_4 = \beta_5 \end{cases}$$

- Regressão auxiliar

$$\begin{aligned} \ln salary &= \beta_0 + \beta_1 years + \beta_2 gamesyr + \beta_3 bavg + \beta_4 hrunsyr + \beta_5 rbisyr + u \\ &= \beta_0 + 0.1 years + \beta_2 gamesyr + \beta_3 bavg + \beta_5 hrunsyr + \beta_5 rbisyr + u \end{aligned}$$

$$\ln salary - 0.1 years = \beta_0 + \beta_2 gamesyr + \beta_3 bavg + \beta_5 (hrunsyr + rbisyr) + u$$

(ver output no slide seguinte)

$$F_{obs} = \frac{(186.674 - 183.186)/2}{183.186/(353 - 5 - 1)} = 3.3037 \quad F_{0.05}(2; 347) = 3.022$$

$$p - \text{value} = P(F \geq 3.3037) = 0.0379 \quad \text{Rejeita } H_0 \text{ para } \alpha = 0.05$$

# Testes sobre várias combinações lineares – caso geral

Exemplo: output da regressão auxiliar

$$\ln \text{salary} - 0.1 \text{ years} = \beta_0 + \beta_2 \text{gamesyr} + \beta_3 \text{bavg} + \beta_5 (\text{hrunsyr} + \text{rbisyr}) + u$$

SUMMARY OUTPUT		ln(salary)-0.1*years				
Regression Statistics						
Multiple R	0.691355747					
R Square	0.477972769					
Adjusted R Square	0.473485429					
Standard Error	0.731357498					
Observations	353					
ANOVA						
	df	SS	MS	F	Significance F	
Regression	3	170.9207773	56.97359242	106.5158331	5.65962E-49	
Residual	349	186.6744424	0.534883789			
Total	352	357.5952197				
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	11.19091343	0.272181054	41.11569581	7.6181E-136	10.65559194	11.72623493
gamesyr	0.010532168	0.001858351	5.667481593	3.03747E-08	0.006877193	0.014187143
bavg	0.000878062	0.001074004	0.817559631	0.414166471	-0.001234272	0.002990396
hrunsyr+rbisyr	0.011681257	0.002298988	5.081043186	6.12886E-07	0.007159643	0.016202871

# Anexos à parte 1

# Teorema de Frisch-Waugh - demonstração

Demonstração:

Iremos provar, sem perda de generalidade, para  $j = 1$  que  $\hat{\beta}_1 = \frac{\sum_{i=1}^n \hat{r}_{i1} y_i}{\sum_{i=1}^n \hat{r}_{i1}^2}$

Considerem-se as 3 regressões:

1.  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \dots + \hat{\beta}_k x_k$
2.  $\hat{x}_1 = \hat{\alpha}_0 + \hat{\alpha}_2 x_2 + \dots + \hat{\alpha}_k x_k$  sendo  $\hat{r}_{i1}$  os resíduos deste modelo, isto é,  
 $x_{i1} = \hat{x}_{i1} + \hat{r}_{i1}$
3.  $\hat{y} = \hat{\gamma}_0 + \hat{\gamma}_1 \hat{r}_{i1}$

Quer-se provar que  $\hat{\gamma}_1 = \hat{\beta}_1$ .

Parte-se das condições de 1ª ordem na determinação de  $\hat{\beta}$  (modelo 1), mais particularmente da equação com  $j = 1$

$$\sum_{i=1}^n x_{i1} (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \dots - \hat{\beta}_k x_{ik}) = \sum_{i=1}^n x_{i1} (y_i - \hat{y}_i) = \sum_{i=1}^n x_{i1} \hat{u}_i = 0$$

Substituindo  $x_{i1}$  por  $\hat{x}_{i1} + \hat{r}_{i1}$  (modelo 2) vem

$$\sum_{i=1}^n (\hat{x}_{i1} + \hat{r}_{i1}) \hat{u}_i = \sum_{i=1}^n \hat{x}_{i1} \hat{u}_i + \sum_{i=1}^n \hat{r}_{i1} \hat{u}_i = 0 \quad (A)$$

# Teorema de Frisch-Waugh - demonstração

Mas

$$\begin{aligned}\sum_{i=1}^n \hat{x}_{i1} \hat{u}_i &= \sum_{i=1}^n (\hat{\alpha}_0 + \hat{\alpha}_2 x_{i2} + \dots + \hat{\alpha}_k x_{ik}) \hat{u}_i \\ &= \hat{\alpha}_0 \sum \hat{u}_i + \hat{\alpha}_2 \sum x_{i2} \hat{u}_i + \dots + \hat{\alpha}_k \sum x_{ik} \hat{u}_i = 0 \\ &\quad (\text{propriedades 1 e 2 dos resíduos OLS no mod 1})\end{aligned}$$

$$\begin{aligned}\sum_{i=1}^n \hat{r}_{i1} \hat{u}_i &= \sum_{i=1}^n \hat{r}_{i1} (y_i - \hat{y}_i) = \sum \hat{r}_{i1} y_i - \sum \hat{r}_{i1} \hat{y}_i \\ &= \sum \hat{r}_{i1} y_i - \sum \hat{r}_{i1} (\hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \dots + \hat{\beta}_k x_{ik}) \quad \text{modelo 1} \\ &= \sum \hat{r}_{i1} y_i - \hat{\beta}_0 \sum \hat{r}_{i1} - \hat{\beta}_1 \sum x_{i1} \hat{r}_{i1} - \hat{\beta}_2 \sum x_{i2} \hat{r}_{i1} - \dots - \hat{\beta}_k \sum x_{ik} \hat{r}_{i1} \\ &= \sum \hat{r}_{i1} y_i - \hat{\beta}_1 \sum x_{i1} \hat{r}_{i1} \\ &\quad \text{já que } \sum \hat{r}_{i1} = 0 \text{ e } \sum x_{ij} \hat{r}_{i1} = 0 \text{ para } j = 2, \dots, k \text{ prop resid modelo 2} \\ &= \sum \hat{r}_{i1} y_i - \hat{\beta}_1 \sum \hat{r}_{i1}^2 \quad \text{já que } \sum x_{i1} \hat{r}_{i1} = \sum (\hat{x}_{i1} + \hat{r}_{i1}) \hat{r}_{i1} = \sum \hat{x}_{i1} \hat{r}_{i1} + \sum \hat{r}_{i1}^2 \\ &\quad \text{e } \sum \hat{x}_{i1} \hat{r}_{i1} = 0 \text{ (prop resid modelo 2)}\end{aligned}$$

E portanto, voltando a (A) temos

$$\sum \hat{r}_{i1} y_i - \hat{\beta}_1 \sum \hat{r}_{i1}^2 = 0 \text{ isto é } \hat{\beta}_1 = \frac{\sum \hat{r}_{i1} y_i}{\sum \hat{r}_{i1}^2} \text{ que é a expressão de } \hat{\gamma}_1 \text{ (slide 17 estimação dos coeficientes)}$$

# Efeito da adição de uma variável - dem

## Demonstração

Considere-se, sem perda de generalidade, o caso em que  $j = 1$  e  $r = k$ . Quer provar-se  $\tilde{\beta}_1 = \hat{\beta}_1 + \hat{\beta}_k \delta_1$ .

Considerem-se as 2 regressões:

1.  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \dots + \hat{\beta}_{k-1} x_{k-1} + \hat{\beta}_k x_k$       modelo completo

2.  $y = \tilde{\beta}_0 + \tilde{\beta}_1 x_1 + \dots + \tilde{\beta}_{k-1} x_{k-1} + \tilde{v}$       modelo sem  $x_k$

Aplica-se o Teorema de Frisch-Waugh ao modelo sem  $x_k$ , isto é, definindo  $\tilde{r}_{i1}$  como sendo os resíduos do modelo  $\tilde{x}_1 = \tilde{\alpha}_0 + \tilde{\alpha}_2 x_2 + \dots + \tilde{\alpha}_{k-1} x_{k-1}$  (3) vem  $\tilde{\beta}_1 = \frac{\sum_{i=1}^n \tilde{r}_{i1} y_i}{\sum_{i=1}^n \tilde{r}_{1i}^2}$

# Efeito da adição de uma variável - dem

Ora

$$\sum \tilde{r}_{i1} y_i = \sum \tilde{r}_{i1} (\hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \dots + \hat{\beta}_k x_{ik} + \hat{u}_i) \quad \text{utilizar regressão 1}$$

$$= \hat{\beta}_0 \sum \tilde{r}_{i1} + \hat{\beta}_1 \sum \tilde{r}_{i1} x_{i1} + \dots + \hat{\beta}_k \sum \tilde{r}_{i1} x_{ik} + \sum \tilde{r}_{i1} \hat{u}_i$$

$$= \hat{\beta}_1 \sum \tilde{r}_{i1} x_{i1} + \hat{\beta}_k \sum \tilde{r}_{i1} x_{ik} + \sum \tilde{r}_{i1} \hat{u}_i \quad \text{já que } \tilde{r}_{i1} \text{ tem soma nula e é ortogonal a } x_2, x_3, \dots, x_{k-1} \text{ (propriedades dos resíduos modelo 3)}$$

$$\sum \tilde{r}_{i1} \hat{u}_i = \sum (x_{i1} - \hat{\alpha}_0 - \hat{\alpha}_2 x_{i2} - \dots - \hat{\alpha}_{k-1} x_{ik-1}) \hat{u}_i \quad \text{definição de } \tilde{r}_{i1} \text{ (mod 3)}$$

$$= \sum x_{i1} \hat{u}_i - \hat{\alpha}_0 \sum \hat{u}_i - \hat{\alpha}_2 \sum x_{i2} \hat{u}_i - \dots - \hat{\alpha}_{k-1} \sum x_{ik-1} \hat{u}_i$$

$$= 0 \quad \hat{u}_i \text{ tem soma nula e é ortogonal a } x_2, x_3, \dots, x_{k-1} \text{ (prop res mod 1)}$$

$$\sum \tilde{r}_{i1} x_{i1} = \sum \tilde{r}_{i1} (\hat{\alpha}_0 + \hat{\alpha}_2 x_{i2} + \dots + \hat{\alpha}_{k-1} x_{ik-1} + \tilde{r}_{i1}) \quad \text{utiliza-se o modelo 3}$$

$$= \hat{\alpha}_0 \sum \tilde{r}_{i1} + \hat{\alpha}_2 \sum \tilde{r}_{i1} x_{i2} + \dots + \hat{\alpha}_{k-1} \sum \tilde{r}_{i1} x_{ik-1} + \sum \tilde{r}_{i1}^2$$

$$= \sum \tilde{r}_{i1}^2 \quad \text{propriedades de } \tilde{r}_{i1} \text{ vistas anteriormente}$$

$$\text{E portanto } \tilde{\beta}_1 = \frac{\sum_{i=1}^n \tilde{r}_{i1} y_i}{\sum_{i=1}^n \tilde{r}_{i1}^2} = \frac{\hat{\beta}_1 \sum \tilde{r}_{i1} x_{i1} + \hat{\beta}_k \sum \tilde{r}_{i1} x_{ik} + \sum \tilde{r}_{i1} \hat{u}_i}{\sum \tilde{r}_{i1}^2} = \frac{\hat{\beta}_1 \sum \tilde{r}_{i1}^2 + \hat{\beta}_k \sum \tilde{r}_{i1} x_{ik}}{\sum \tilde{r}_{i1}^2}$$

# Efeito da adição de uma variável - dem

Logo

$$\tilde{\beta}_1 = \frac{\hat{\beta}_1 \sum \tilde{r}_{i1}^2 + \hat{\beta}_k \sum \tilde{r}_{i1} x_{ik}}{\sum \tilde{r}_{i1}^2} = \hat{\beta}_1 + \hat{\beta}_k \left( \frac{\sum \tilde{r}_{i1} x_{ik}}{\sum \tilde{r}_{i1}^2} \right)$$

Como  $\tilde{\delta}_1$  é o coeficiente de  $x_1$  na regressão de  $x_k$  em  $(x_1, x_2, \dots, x_{k-1})$  a regressão auxiliar para aplicar o teorema de Frisch-Waugh será a de  $x_1$  em  $(x_2, \dots, x_{k-1})$  que corresponde ao modelo 3 de resíduos  $\tilde{r}_{i1}$  e portanto

$$\tilde{\delta}_1 = \frac{\sum_{i=1}^n \tilde{r}_{i1} x_{ik}}{\sum_{i=1}^n \tilde{r}_{i1}^2}.$$

Assim  $\tilde{\beta}_1 = \hat{\beta}_1 + \hat{\beta}_k \tilde{\delta}_1$  como se queria mostrar